



Der Faktor Mensch in quantitativen Fahrermodellen des Folgefahrens: Ein Modellvergleich

The human factor in quantitative car-following models: A model comparison

Masterarbeit

Lehrstuhl für Ingenieur- und Verkehrspsychologie
Technische Universität Braunschweig

Vorgelegt von: Diana Kuhl
Neustadtring 55
38114, Braunschweig
Matrikelnummer: 4312688

Erstgutachter: Prof. Dr. Mark Vollrath
Zweitgutachterin: Dr. Meike Jipp

Braunschweig, den 23.03.2015

Zusammenfassung

Anderen Fahrzeugen zu folgen ist eine Aufgabe, die wir als Autofahrer regelmäßig ausführen müssen. Die Art und Weise, wie wir diese Aufgabe lösen, beeinflusst z.B. die Entstehung von Staus oder Auffahrunfällen. Um diese Ereignisse analysieren und Vorhersagen ableiten zu können, wurden (zumeist in den Ingenieurwissenschaften) quantitative Fahrermodelle entwickelt, die Folgefahrverhalten simulieren können. Allerdings lösen die meisten dieser Modelle die Folgefahraufgabe nicht auf eine psychologisch plausible Weise, da sie z.B. eine exakte Distanz oder Geschwindigkeit des Vorderfahrzeugs als Eingangssignal nutzen. In ersten Ansätzen wurde jedoch versucht, psychologische Erkenntnisse in diese Modelle zu integrieren. Einer dieser Ansätze ist die Entwicklung des Driving-by-Visual-Angle-Modells (DVA-Modell) von Andersen und Sauer (2007). Hier wird als einziges Eingangssignal der Sehwinkel genutzt. Die Frage ist, ob sich dadurch Folgefahrverhalten besser vorhersagen lässt. Zur Beantwortung dieser Frage wurde in dieser Arbeit das DVA-Modell mit den zwei etablierten Modellen von Helly (1959) und Gipps (1981) verglichen. Als viertes Modell wurde eine hier vorgenommene Erweiterung des DVA-Modells in den Vergleich mitaufgenommen. Diese Erweiterung enthält eine Wahrnehmungsschwelle. Damit soll der Einfluss einer weiteren psychologischen Komponente auf die Vorhersagegüte quantitativer Fahrermodelle getestet werden. Es wurden Realfahrtdaten von zwölf Probanden während einer Folgefahrt in drei verschiedenen Fahrsituationen gewonnen: auf der Autobahn, Landstraße und in der Stadt. Für alle drei Streckentypen wurden Modellvorhersagen für das Folgeverhalten generiert und mit den empirischen Daten verglichen. Die Ergebnisse dieser Arbeit zeigen, dass das DVA-Modell und seine Erweiterung schlechtere Vorhersagen machten als die anderen beiden Modelle. Dies galt für die Vorhersagen aller drei Streckentypen. Dennoch hat der Faktor Streckentyp in dieser Stichprobe einen Einfluss auf das allgemeine Niveau der Vorhersagegüte. Es stellte sich weiterhin heraus, dass alle Modelle vielmehr das Vorderfahrzeug synchronisieren, als dass sie das Profil des Folgefahrzeugs wiedergeben. Einzelne Maßnahmen, Modelle in ihrer psychologischen Plausibilität zu erhöhen, wie mit der Nutzung des Sehwinkels oder der Wahrnehmungsschwelle, scheinen für die Vorhersagen demnach noch keinen erkennbaren Mehrwert zu bieten. Nichts desto trotz zeigt diese Arbeit Chancen auf, wie die quantitative Modellierung als Methode die psychologische Forschung bereichern kann und wo derzeit noch ihre Grenzen liegen.

Stichwörter: Folgefahren, kognitive Fahrermodelle, Modellvergleich, DVA-Modell

Abstract

Following other vehicles is a driving task, we are frequently exposed to. The way we solve this task influences the development of traffic jams or the occurrence of rear-end collisions. To analyse and predict those incidents, quantitative driver models were built (mostly done within the engineering sciences) that simulate car following behaviour. However, these models do not solve the car-following task in a psychologically plausible manner, as they use exact distance and speed of the leading vehicle as input signals. There are first attempts that try to integrate psychological findings into such models. One of them is the driving-by-visual-angle-model (DVA-model) by Andersen and Sauer (2007). The only input signal of the DVA-model is the visual angle. The question is, if by using the visual angle, predictions of car-following behaviour improve. To answer this question, this study compares the DVA-model with two well-established models of Helly (1959) and Gipps (1981). The DVA-model was further adjusted, by adding a perception threshold. This new model is the fourth model of the comparison and includes another psychological characteristic. Real driving data of twelve participants following another vehicle were collected. Three different driving scenarios were observed: driving on a highway, country road and through urban areas. For all three scenarios, model predictions were generated and compared to empirical data. Results show, that the DVA-model and its adjustment perform weaker than the other two. This is true for all three scenarios. Although the overall level of the goodness of fit differs between the scenarios. Further results reveal that all models primarily synchronise the driving profile of the leading vehicle instead of predicting the following vehicle. Single actions to improve models in order to increase psychological plausibility, like a visual angle or perception threshold, have no additional benefit for predictions of empirical data. However, this study identifies chances for quantitative modeling enriching psychological sciences but also states its limits.

Keywords: car-following, cognitive driver model, model comparison, DVA-model

Inhaltsverzeichnis

1	Einleitung	1
2	Theorie	3
2.1	Arten von Fahrermodellen	3
2.2	Die Fahraufgabe des Folgefahrens	3
2.3	Folgefahrtmodelle – ein Überblick	4
2.3.1	Ursprungsmodell	4
2.3.2	Lineare Modelle (Helly-Modell)	7
2.3.3	Kollisions-vermeidende Modelle (Gipps-Modell)	8
2.3.4	Schwinkelmodelle (das DVA-Modell)	10
2.3.5	Modelle mit Wahrnehmungsschwellen	11
2.4	Bisherige Vergleichsstudien	13
2.4.1	Individuelle Unterschiede	14
2.4.2	Einfluss der Fahrsituation	15
2.4.3	Variable der Vorhersagen	16
2.4.4	Gütemaß	16
3	Fragestellungen	18
4	Methode	21
4.1	Unabhängige Faktoren	21
4.2	Abhängige Faktoren	22
4.3	Modellkalibrierung	23
4.3.1	Parametergrenzen	24
4.3.2	Startparameter	25
4.4	Stichprobe	26
4.5	Durchführung	26
4.6	Versuchsmaterial	27
4.6.1	Technische Details	29
4.6.2	Versuchsstrecke	29
4.7	Datenanalyse	30
4.7.1	Datenaufbereitung	31

4.7.2	Statistische Analysen.....	32
5	Ergebnisse	33
5.1	Deskriptive Auswertung der empirischen Daten.....	33
5.2	Verlaufsdiagramme	34
5.3	Analyse des Interaktionseffekts zwischen Modell und Streckentyp (Fragestellung 1)...	35
5.4	Analyse der Unterschiede zwischen Streckentypen (Fragestellung 2).....	38
5.5	Analyse der Modellunterschiede (Fragestellung 3).....	39
6	Diskussion.....	40
6.1	Beantwortung der Fragestellungen	40
6.2	Schlussfolgerungen.....	42
6.2.1	Modellvergleich	42
6.2.2	Streckentypen	43
6.2.3	Variable der Vorhersage.....	44
6.2.4	Gütemaße	45
6.2.5	Individuelle Unterschiede	46
6.3	Reflexion der Stärken und Grenzen dieser Arbeit.....	46
6.4	Fazit	47
	Literaturverzeichnis.....	48
	Anhang	53

Tabellenverzeichnis

Tabelle 1: Versuchsdesign	22
Tabelle 2: Modellparameter mit ihren Wertegrenzen und Beschreibungen	24
Tabelle 3: Startparameter	25
Tabelle 4: Deskriptive Kennwerte der empirischen Daten	33

Abbildungsverzeichnis

Abbildung 1: Verlaufsdiagramme für Geschwindigkeit und Distanz eines Ausschnitts der Fahrt von Proband sieben mit Vorhersagen des Modells von Pipes (1953)	6
Abbildung 2: Foto des Versuchsfahrzeugs, das von den Probanden geführt wurde	28
Abbildung 3: Karte mit Markierung der Versuchsstrecke	30
Abbildung 4: Verlaufsdiagramm für die Geschwindigkeit eines Ausschnitts der Fahrt von Proband sechs mit Modellvorhersagen	34
Abbildung 5: Verlaufsdiagramm für die Distanz eines Ausschnitts der Fahrt von Proband sechs mit Modellvorhersagen	35
Abbildung 6: Modellgüte für alle Modelle getrennt für die Streckentypen pro Variable und Gütemaß	37

1 Einleitung

Das Folgen eines vorausfahrenden Fahrzeugs gehört zu den häufigsten Aufgaben beim Autofahren. Aber wie löst der menschliche Autofahrer diese Aufgabe? Welche Eingangssignale nutzt er, um daraufhin den Abstand zum Vorderfahrzeug anzupassen?

Die quantitative Modellierung von Fahrverhalten bei der Folgefahrt kann als Methode zur Beantwortung dieser Fragen von hohem Nutzen sein, wurde in der Verkehrspsychologie bislang aber kaum in Betracht gezogen. Dabei kann mit Hilfe von Modellierung das menschliche Fahrverhalten simuliert werden. Das Prinzip der Modellierung kann wie folgt beschrieben werden: Ein Modell stellt ein Abbild kognitiver Prozesse dar. Es erhält Eingangssignale aus der Umwelt, verarbeitet diese und produziert anschließend Vorhersagen für Fahrverhalten. Durch einen Vergleich dieser Vorhersagen mit den Fahrdaten echter Personen, kann ein Modell auf seine Plausibilität hin überprüft werden. Modellierung ergänzt die klassischen Methoden der Psychologie also, indem mit ihr zusätzlich überprüft werden kann wie – und nicht nur ob – bestimmte Variablen einen Einfluss nehmen. Das macht die Modellierung zu einer wertvollen Methode für die Grundlagenforschung der Kognitionspsychologie beim Autofahren. In diesem Forschungszweig wurde sie bislang jedoch nur in ersten Ansätzen eingesetzt (Van Winsum, 1999).

Die Modellierung des menschlichen Fahrers wird hingegen intensiv in der anwendungsorientierten Forschung und Entwicklung verwendet. Dabei sind es allerdings andere Wissenschaften als die Psychologie, die quantitative Modelle konstruieren und weiterentwickeln – darunter die Ingenieurs- und Verkehrswissenschaften, sowie die Informatik. Sie nutzen die Simulation menschlichen Fahrverhaltens in frühen Entwicklungsstufen der Fahrzeugkonstruktion. So können potentielle Probleme in der Interaktion zwischen Mensch und System bei der Weiterentwicklung berücksichtigt werden. Auf aufwändige Erhebungen, für die eigens Prototypen angefertigt werden müssen, kann dann verzichtet werden. Der Anspruch dieser Wissenschaften liegt meist auf einer möglichst exakten Nachahmung von Fahrverhalten. Mit einem Fahrermodell ein Abbild menschlicher Kognition zu schaffen, steht nicht im Vordergrund. Dementsprechend liegen zwar Fahrermodelle für die Folgefahrt vor, aber keine kognitiven Fahrermodelle. Bereits in den 50er Jahren entstanden im Rahmen der Ingenieurwissenschaften die ersten Folgefahrtmodelle (Brackstone & McDonald, 1999) und wurden in den darauffolgenden Jahrzehnten soweit entwickelt, dass sie Folgefahren zufriedenstellend

vorhersagen konnten. Ein Abbild menschlicher Kognitionen bilden sie allerdings nicht, da sie offensichtliche oder bereits bekannte Grenzen menschlicher Fähigkeiten überschreiten. Z.B. nutzen die Modelle als Eingangssignal exakte Geschwindigkeiten des Vorderfahrzeugs (Gipps, 1981; Helly, 1959), was den Wahrnehmungsfähigkeiten des Menschen nicht entspricht. Doch genau diese Art und Weise der Informationsverarbeitung ist das, was die Psychologie beabsichtigt herauszufinden. Dieses Wie mit Hilfe quantitativer Fahrermodelle zu definieren könnte also in Zukunft die Aufgabe der Psychologie sein, um somit mehr über die menschliche Kognition zu erfahren. Vereinzelt gab es Ansätze bereits existierende Modelle psychologisch plausibler zu formulieren (Andersen & Sauer, 2007; Hoogendoorn, Hoogendoorn, Brookhuis, & Daamen, 2010; Michaels, 1963; Soria, Elefteriadou, & Kondyli, 2014; Wiedemann & Reiter, 1992). Darunter ist auch das DVA-Modell (driving by visual angle) von Andersen und Sauer (2007). Es verzichtet auf die Distanz als direktes Eingangssignal des Modells und ersetzt sie durch den Sehwinkel, den das Vorderfahrzeug im Blickfeld des Fahrers einnimmt. Der Vorteil liegt darin, dass die Nutzung des Sehwinkels mit der Tatsache konform geht, dass die menschliche Retina nur eine zweidimensionale Abbildung der Umwelt zulässt. Das steigert nach Andersen und Sauer (2007) die psychologische Plausibilität des Modells. Weiterhin hat die Verwendung des Sehwinkels eine geringere Gewichtung von Veränderungen bei großen Distanzen im Vergleich zu kleinen Distanzen zur Folge.

Das DVA-Modell wurde bei Andersen und Sauer (2007) nur anhand eines Probanden im realen Kontext mit einem anderen Modell verglichen, sodass noch unklar ist, ob es eine bessere Vorhersagegüte liefert als andere Modelle. Generell wurde der Einfluss solcher Maßnahmen, Modelle der Folgefahrt psychologisch plausibler zu machen, noch nicht systematisch und an einem umfangreichen Datensatz getestet. In der hier vorliegenden Arbeit soll diese Lücke geschlossen werden und die Frage anhand eines aussagekräftigen Datensatzes beantwortet werden, ob psychologisch plausiblere Modelle menschliches Fahrverhalten bei der Folgefahrt besser vorhersagen können. Zum Vergleich dienen zwei etablierte Folgefahrtsmodelle aus den Ingenieurwissenschaften.

2 Theorie

2.1 Arten von Fahrermodellen

Im Laufe der letzten Jahrzehnte zeichneten sich im Rahmen der allgemeinen Fahrermodellierung verschiedene Themenschwerpunkte und Herangehensweisen ab. Neben Folgefahrtmodellen, die hier betrachtet werden, existieren sowohl Modelle für Spurwechselvorgänge (Gipps, 1986; Hashimoto, Suetomi, Okuno, & Uemura, 2001; Hidas, 2005), als auch Modelle für die freie Fahrt (Gipps, 1981; Prokop, 2001). Modelle lassen sich aber nicht nur anhand der durch sie abgebildeten Fahraufgabe unterscheiden. Auch hinsichtlich ihrer Methodik weisen sie Unterschiede auf. Innerhalb der quantitativen Fahrermodellierung kann zwischen Modellen in Form von mathematischen Gleichungen, wie z.B. Differenzialgleichungen bei Reglermodellen, oder Modellen in Form von Algorithmen differenziert werden (Sun, 2008). Ein weiteres Unterscheidungsmerkmal von Fahrermodellen ist die Unterscheidung zwischen Makro- und Mikromodellierung. Diese Unterscheidung ist vor allem für die Aufgabe des Folgefahrens relevant, und lässt sich daran am besten erklären, da hier häufig nicht nur einzelne Fahrzeugtrajektorien beschrieben werden sollen, sondern ganze Verkehrsflüsse z.B. zur Simulation von Staus. Die Makromodellierung verfolgt dabei den Ansatz ein einziges Modell für die Gesamtheit aller Fahrzeuge eines Verkehrsszenarios zu entwickeln. Relevant sind ausschließlich Größen, die diese Gesamtheit beschreiben können, wie z.B. die durchschnittliche Geschwindigkeit und Verkehrsdichte (Krauß, 1998). Die Mikromodellierung richtet hingegen ihren Fokus auf die Bewegungen des einzelnen Verkehrsteilnehmers und des ihm vorausfahrenden Fahrzeugs. Hier werden Größen wie Beschleunigung, Geschwindigkeit und Distanz zum Vorderfahrzeug betrachtet. Der Verkehrsfluss wird dann durch das Zusammenspiel mehrerer Mikromodelle abgebildet.

Das DVA-Modell, das hier betrachtet werden soll, gehört der Gruppe der mathematisch formulierten Mikromodelle für die Aufgabe des Folgefahrens an. Dementsprechend stammen auch die weiteren Modelle, die hier mit in den Vergleich aufgenommen werden, aus dieser Gruppe.

2.2 Die Fahraufgabe des Folgefahrens

Das Folgefahren ist eine von vielen Aufgaben, die es beim Autofahren zu bewältigen gilt. Michon (1985) unterteilte das gesamte Aufgabenspektrum des Fahrens in drei Ebenen:

Navigation (Wahl der Route), Führung (Geschwindigkeitswahl, Beachten von Verkehrsvorschriften) und Stabilisierung (Wahl der Trajektorie mit Spurhalten, Abbremsen und Beschleunigen). Folgefahren lässt sich vor allem den Kategorien der Führung und der Stabilisierung zuordnen (Ossen, 2008), wobei letzterer in dieser Arbeit ein größerer Stellenwert zukommen mag, weil es hier um das reine Abstandsverhalten zum Vorderfahrzeug geht. Die Stabilisierungsaufgabe beinhaltet die Längsführung – reguliert durch die Wahl der Geschwindigkeit über Bremsen und Beschleunigen – als auch die Querführung, die durch die Lenkung gesteuert wird. Die Fahrermodelle, die hier betrachtet werden, modellieren lediglich die Längsführung. Der Aspekt der Querführung spielt in den hier vorgestellten Modellen keine Rolle.

Die Stabilisierungsaufgabe ist eine Regelaufgabe und wurde besonders in den 50er Jahren mit klassischen mathematischen Reglermodellen beschrieben (Jürgensohn, 1997). Die reale Distanz zum Vorderfahrzeug kann als Ist-Wert verstanden werden – die gewünschte Distanz als Soll-Wert. Ihre Abweichung bestimmt wiederum die Veränderung des Ist-Werts für den nächsten Zeitpunkt. Innerhalb dieses Schemas übernimmt der Mensch die Rolle des Reglers, der die Abweichung zwischen Ist und Soll über die Zeit hinweg minimiert – hier entsprechend durch Beschleunigen oder Bremsen. Die Anwendung von Reglermodellen zur Beschreibung der menschlichen Interaktion mit Maschinen war zu dieser Zeit populär (Jürgensohn, 1997) und fand nicht nur in der Fahrzeugführung Verwendung, sondern auch in der Flugführung (Baron, Elkind, Kleinman, Duncan, & Levison, 1969) und Arbeitsplatzgestaltung (Timpe, 1966).

2.3 Folgefahrtmodelle – ein Überblick

Im Folgenden soll ein kurzer Überblick über die zentralen Modelle der Folgefahrt gegeben werden, der gleichzeitig auch eine Vorstellung der hier verwendeten Modelle ist.

2.3.1 Ursprungsmodell

Im Zuge der Hochphase der Reglermodelle wurden auch die ersten Folgefahrtmodelle in den 50er Jahren in Form von Reglermodellen konstruiert. Eines der ersten Modelle dieser Art konzipierte Pipes (1953). Es beschreibt das Folgefahrverhalten als Synchronisation der Geschwindigkeit des Vorderfahrzeugs. In der Sprache der Regler stellt die Geschwindigkeit des Vorderfahrzeugs v_{VF} damit den Soll-Wert dar. Weiterhin wird die Abweichung der tatsächlichen, also eigenen Geschwindigkeit v_{FF} von diesem Soll-Wert bestimmt. Diese Differenz wird

zusätzlich durch einen Faktor s gewichtet, der reguliert wie stark die Abweichung in der Reaktion bzw. der Vorhersage berücksichtigt wird – er repräsentiert also die Sensitivität für die Abweichung. Daraus resultiert schließlich die Vorhersage in Form der Beschleunigung a . Mathematisch ausgedrückt, lautet es wie folgt:

$$a = s \cdot [v_{VF} - v_{FF}] \quad (1)$$

In dieser Gleichung fehlt jedoch noch die zeitliche Komponente. Schließlich wird nicht nur eine einmalige Vorhersage generiert, vielmehr soll eine gesamte Fahrt vorhergesagt werden. Dies trifft auf alle Modelle dieser Art zu, sodass die folgenden Erklärungen zum allgemeinen Verständnis der hier verwendeten Modelle beitragen sollen.

Die gesamte Fahrt wird unterteilt in diskrete Zeiteinheiten der Länge T . Beispielsweise werden jede Sekunde Vorhersagen generiert, also $T = 1\text{s}$. Der absolute Zeitpunkt zu dem die Vorhersage gemacht wird, wird mit t gekennzeichnet. Zu jedem Zeitpunkt erhält das Modell als Eingangssignal die empirisch gemessene Geschwindigkeit des Vorderfahrzeugs des vorherigen Zeitpunkts. Dieser wird also mit $t-T$ beschrieben. Die Geschwindigkeit des Folgefahrzeugs, also die eigene Geschwindigkeit, bezieht es wiederum aus seiner vorherigen Modellvorhersage des Zeitpunkts $t-T$. Die vollständige Gleichung von Pipes lautet schließlich:

$$a(t) = s \cdot [v_{VF}(t - T) - v_{FF}(t - T)] \quad (2)$$

Mit der Anfangsgeschwindigkeit und der Kumulierung der vorhergesagten Beschleunigungswerte, lassen sich die Modellvorhersagen auch als Geschwindigkeitsprofil berechnen. Mit der Anfangsdistanz zwischen beiden Fahrzeugen, lässt sich ebenso durch Kumulierung der Geschwindigkeit die durch das Modell vorhergesagte Distanz für die gesamte Fahrt berechnen. Der Geschwindigkeits- und Distanzverlauf des Folgefahrzeugs ist somit allein durch das Modell konstruiert, während es – wie der echte Fahrer – nur die Information über das Vorderfahrzeug erhält. Abbildung 1 stellt zur Veranschaulichung die Vorhersagen des Modells für einen Ausschnitt der Fahrt von Proband sieben durch die Stadt dar, sowohl für die Geschwindigkeit (oben), als auch die Distanz (unten). Anhand der Abbildung ist zu sehen, dass das Pipes-Modell eine perfekte Synchronisation der Geschwindigkeit des Vorderfahrzeugs ist.

Somit verändert sich der Abstand zum Vorderfahrzeug über die gesamte Fahrt hinweg nicht.




Abbildung 1. Verlaufsdiagramm mit der empirisch gemessenen Geschwindigkeit von Vorder- und Folgefahrzeug (oben) und deren Distanz (unten) eines Ausschnitts der Fahrt von Proband sieben, sowie die entsprechenden Vorhersagen des Modells von Pipes (1953).

Der Parameter s ist über die Fahrt hinweg konstant. Der genaue Wert muss so gewählt werden, dass das Modell die bestmöglichen Vorhersagen generiert, also den empirischen Daten möglichst gleicht. Diese Art von Parametern nennen sich freie Parameter und sind auch in allen hier vorgestellten Modellen enthalten. Um den optimalen Parameterwert zu finden, werden Modellvorhersagen mit einer Vielzahl möglicher Parameterwerte generiert und mit den empirisch gemessenen Daten, die es vorherzusagen gilt, verglichen. Der Parameterwert, bei dem die Modellvorhersagen den empirischen Daten am ähnlichsten sind, wird schlussendlich für das Modell ausgewählt. Dieser Vorgang nennt sich Kalibrierung. Welchen Wert der freie Parameter annimmt, ist somit auch abhängig vom jeweiligen Datensatz, z.B. welche Person, wo und mit welchem Fahrzeug gefahren ist.

Die Weiterentwicklungen des Modells von Pipes (1953) bahnten den Weg zu den später entwickelten Modellen von Helly (1959), sowie dem DVA-Modell von Andersen und Sauer (2007), die in dieser Arbeit verglichen werden sollen. Als erste Weiterentwicklung des ursprünglichen Modells wurde im sogenannten Chandler-Modell eine Reaktionszeitkomponente mitaufgenommen (Chandler, Herman, & Montroll, 1958), indem die Zeiteinheit T die Länge der Reaktionszeit annimmt. Im Folgenden kennzeichnen wir dies mit T_r . Dies war eine erste Maßnahme, die unrealistisch exakte Synchronisation des Geschwindigkeitsprofils des Vorderfahrzeugs, hin zu realistischeren Vorhersagen zu verändern. Grazis, Herman und Potts (1959) und Grazis, Herman und Rothery (1961) führten weiterhin die Distanz zum Vorderfahrzeug ein, an welcher der Geschwindigkeitsunterschied der Fahrzeuge relativiert wird. Der dadurch resultierende Effekt ist eine stärkere Gewichtung der Geschwindigkeitsabweichung bei geringen Distanzen. Entsprechend der Namen der Autoren des Modells nennt es sich GHR-Modell.

2.3.2 Lineare Modelle (Helly-Modell)

Helly (1959) erweiterte das Pipes-Modell, indem er zum bestehenden Term einen weiteren addierte. Das Helly-Modell wird auch als ein Stellvertreter linearer Modelle bezeichnet (Brackstone & McDonald, 2000). Neben der Abweichung der Geschwindigkeit wie sie im Pipes-Modell genutzt wird, beschreibt Helly mit dem zweiten Term zusätzlich die Abweichung von tatsächlicher Distanz zur gewünschten Distanz. Somit lautet das Modell:

$$a(t) = k \cdot [v_{VF}(t - T_r) - v_{FF}(t - T_r)] + j \cdot [d(t - T_r) - d'(t)] \quad (3)$$

Der Index d gibt die tatsächliche Distanz an, während d' die gewünschte Distanz ist. Da Helly annahm, dass die Wunschdistanz mit höherer Geschwindigkeit ebenfalls steigt, wird sie durch folgende Gleichung spezifiziert:

$$d'(t) = d_{min} + f \cdot v_{FF}(t - T_r) \quad (4)$$

Hierbei steht d_{min} für die Distanz, die bei Stillstand beider Fahrzeuge beibehalten wird. Der Parameter f gewichtet, wie stark sich die Wunschdistanz mit der Geschwindigkeit verändert. Somit sind j , k , d_{min} , f und die Reaktionszeit T_r die zu kalibrierenden Parameter des Modells. Die Eingangssignale, die das Modell pro Zeiteinheit erhält sind die Geschwindigkeit des Vorderfahrzeugs und die Distanz zwischen den Fahrzeugen, wobei das Folgefahrgesetz hier durch das Modell repräsentiert wird und es dadurch die Distanz zwischen Vorderfahrzeug und der angenommenen Position durch das Modell ist. Die Vorhersagen des Modells sind Beschleunigungen. Helly (1959) legte in der Originalstudie Grenzen für die Vorhersagen fest, die nicht über- bzw. unterschritten werden durften. Befindet sich eine Vorhersage außerhalb der Grenzen, nimmt sie den Grenzwert an. Er wählte die Werte entsprechend den technischen Möglichkeiten des Simulators, den er in seiner Studie verwendete (1,22 m/s² für positive und 6,10 m/s² für negative). Solche Grenzen sollen in dieser Studie nicht verwendet werden, um die unverfälschte Vorhersagegüte des Modells zu erhalten. Darüber hinaus wurde diese Maßnahme bei dem als nächstes vorgestellten Gipps-Modell nicht unternommen, sodass die Vergleichbarkeit der Modelle darunter leiden würde.

2.3.3 Kollisions-vermeidende Modelle (Gipps-Modell)

Die Kollisions-vermeidenden Modelle wurden von Brackstone und McDonald (2000) als weitere eigenständige Gruppe unter den Folgefahrtmodellen identifiziert. Der am häufigsten verwendete Stellvertreter der Gruppe ist das Folgefahrtmodell von Gipps (1981). Im Gegensatz zu den vorherigen Modellen sagt es nicht die Beschleunigung vorher (also die Veränderung der Geschwindigkeit über die Zeit), sondern die Geschwindigkeit selbst. Auch ist das Ziel nicht mehr die Synchronisation des Vorderfahrzeugs: Der Fokus dieses Modells ist die Wahrung eines

Sicherheitsabstandes zur Vermeidung von Kollisionen – daher auch die Namensgebung dieser Modellgruppe. Die Geschwindigkeit pro Zeiteinheit wird so gewählt, dass bei maximaler Bremsung des Vorderfahrzeugs und unter Berücksichtigung der maximalen Bremskraft des Folgefahrzeugs eine minimale Distanz zwischen den Fahrzeugen beibehalten werden kann. Die Gleichung zu diesem Modell lautet:

$$v(t) = b_{max} \cdot T_r + \sqrt{(b_{max})^2 \cdot T_r^2 - b_{max} \cdot \left(2 \cdot [d(t - T_r) + d_{min}] - v_{FF}(t - T_r) \cdot T_r - \frac{(v_{FF}(t - T_r))^2}{b_{est}} \right)} \quad (5)$$

Auch das Gipps-Modell nutzt die Geschwindigkeit des Vorderfahrzeugs und die Distanz der Fahrzeuge als Eingangssignal. Der Parameter b_{max} stellt die maximale Bremsung dar, die der Fahrer gewillt ist vorzunehmen. Entsprechend dazu ist b_{est} eine Schätzung der maximalen Bremsung, die der Vorderfahrer gewillt ist zu tun. Die minimale Distanz zum Vorderfahrzeug, die der Fahrer nicht unterschreiten möchte, wird mit d_{min} beschrieben. Die Parameter b_{max} , b_{est} , d_{min} und die Reaktionszeit T_r sind die zu kalibrierenden Parameter des Modells. Das ursprüngliche Modell von Gipps beinhaltet zwei Gleichungen. Die zweite Gleichung, die hier nicht betrachtet wird, bezieht sich auf den Fall der freien Fahrt.

Das primäre Ziel der bisher vorgestellten Modelle besteht darin, menschliches Fahrverhalten so gut wie möglich vorherzusagen. Weniger Aufmerksamkeit wird darauf gelegt, dass diese Modelle die Folgeaufgabe lediglich mit den Eingangsgrößen lösen, die auch dem Menschen zur Verfügung stehen. Als Eingangssignale nutzen sie die Distanz und Geschwindigkeit des Vorderfahrzeugs. Dabei ist anzunehmen, dass der Mensch diese nicht direkt und exakt wahrnehmen kann (Van Winsum, 1999). Zugeständnisse müssen jedoch gemacht werden in Hinblick auf die Berücksichtigung der Reaktionszeit und das Einbeziehen eines Wunschwinkels, die individuell kalibriert werden können. Damit wird der Tatsache Rechnung getragen, dass Menschen sich in diesen Punkten unterscheiden. Der Faktor Mensch wird somit in Hinblick auf den Aspekt der individuellen Unterschiede auch schon bei den Modellen von Gipps und Helly im Ansatz berücksichtigt.

2.3.4 Schwinkelmodelle (das DVA-Modell)

Der erste, der die Diskussion über die Plausibilität der Eingangssignale aufnahm war Michaels (1963). Er schlug vor, dass die Distanzwahrnehmung über den Schwinkel stattfindet – also der Winkel, unter dem der Fahrer das Vorderfahrzeug wahrnimmt. Dieser Vorschlag berücksichtigt die Tatsache, dass auf der Netzhaut Tiefe nicht repräsentiert werden kann. Der Schwinkel setzt im Gegensatz zur Distanz keine Tiefenwahrnehmung voraus. Eine weitere Eigenschaft des Schwinkels ist, dass er keine lineare Transformation der Distanz darstellt, sodass Veränderungen von großen Distanzen, nicht die gleiche Schwinkelveränderung bewirken, wie die Veränderung kleiner Distanzen. Auch damit soll sich der menschlichen Wahrnehmungsfähigkeit angenähert werden.

Zunächst wurde durch Michaels (1963) nur der horizontale Schwinkel betrachtet, der durch die Breite des Vorderfahrzeugs bestimmt wird. Weiterhin vernachlässigte er die Tatsache, dass sich der Fahrer nicht immer exakt mittig hinter dem vorwegfahrenden Fahrzeug befindet, sodass der hier vorgeschlagene Schwinkel nicht genau dem tatsächlichen Schwinkel entspricht.

Die relative Geschwindigkeit zum Vordermann kann durch die Ausdehnung des Schwinkels auf der Retina über die Zeit bestimmt werden. Lee (1976) konnte diese These stützen, indem er zeigte, dass Probanden die Zeit bis zum Kontakt mit einem sich nähernden Objekt relativ genau bestimmen konnten, wenn sie lediglich die Veränderungsrate des Schwinkels als Informationsquelle hatten.

Andersen und Sauer (2007) entwickelten mit dem DVA-Modell ein Modell, in dem sie auf die Distanz und Geschwindigkeit als Eingangssignale verzichten und sich des Schwinkels bedienen. Es ist eine Weiterentwicklung des Modells von Helly (1959). Die beiden Terme und Parameter des Helly-Modells werden beibehalten. Das Modell lautet:

$$a(t) = k \cdot \frac{d}{d(t-T_r)} a + j \cdot \left(\frac{1}{a(t-T_r)} - \frac{1}{a'(t)} \right) \quad (6)$$

mit,

$$\alpha'(t) = 2 \cdot \operatorname{atan} \left(\frac{w}{d_{time} \cdot v_{FF}(t-T)} \right) \quad (7)$$

Die Wunschdistanz wird nunmehr zum Wunsch-Schwinkel mit α' , der vom tatsächlichen Schwinkel α abgezogen wird – äquivalent zum zweiten Term im Modell von Helly. Die Modellierung des Wunschwinkels in Gleichung 6 wird hier mithilfe der Autobreite w und der gewünschten Distanz d_{time} – gemessen in Zeit – vorgenommen. Die gewünschte Distanz wird zusätzlich mit der momentanen Geschwindigkeit multipliziert, sodass der gewünschte zeitliche Abstand mit steigender Geschwindigkeit länger wird. Die Modellierung des gewünschten Schwinkels wird in der Originalstudie von Andersen und Sauer (2007) nur vorgeschlagen, aber nicht getestet.

In der Modellgleichung (Gleichung 6) wird anstelle der Differenz zwischen tatsächlichem und gewünschtem Schwinkel, die Differenz ihrer Kehrwerte verwendet. Das hat den Effekt, dass bei großen Distanzen zwischen den beiden Fahrzeugen die Abweichung von der Wunschdistanz eine geringere Rolle spielt als bei kleinen Distanzen. Der erste Term – die relative Geschwindigkeit zwischen den Fahrzeugen – wird nun durch die Veränderung des Schwinkels über die Zeit repräsentiert. Das birgt einen weiteren Vorteil: Ist der Schwinkel klein (also die Distanz groß) wird auch die Veränderung des Schwinkels klein sein, sodass eine schwächere Reaktion produziert wird als wenn der Schwinkel und entsprechend seine Veränderungen groß sind. Die Komponente der Reaktionszeit wurde im DVA-Modell ursprünglich nicht mitaufgenommen. Hier soll sie jedoch mit eingeschlossen werden, damit sich das DVA-Modell zwecks eines systematischen Vergleichs lediglich in der Nutzung des Schwinkels vom Helly-Modell unterscheidet.

Die Parameter j , k , d_{time} und die Reaktionszeit T_r sind die zu kalibrierenden Parameter. Als Eingangssignal erhält das DVA-Modell lediglich den Schwinkel des Vorderfahrzeugs, jedoch von den zwei vorhergehenden Zeiteinheiten, anstatt nur einer, wie bei den anderen Modellen. Auch Andersen und Sauer (2007) legten, wie Helly (1959), Grenzwerte für die Vorhersagen fest. Vorhersagen konnten bei ihnen maximal $2,5 \text{ m/s}^2$ bzw. minimal $-2,5 \text{ m/s}^2$ annehmen. Wie in Kapitel 2.3.2 beschrieben, soll in dieser Arbeit auf diese Maßnahme verzichtet werden.

2.3.5 Modelle mit Wahrnehmungsschwellen

Das Nutzen des Schwinkels ist nur eine Maßnahme, ein Modell der menschlichen Art und Weise des Folgefahrens anzunähern. Eine weitere Erkenntnis aus psychologischen Studien ist die einer Wahrnehmungsschwelle für die relative Geschwindigkeit und für die Veränderung von

Distanzen. Michaels (1963) stellte neben dem Konzept des Schwinkels gleichzeitig auch die Idee einer Wahrnehmungsschwelle für relative Geschwindigkeiten vor. Die relative Geschwindigkeit zweier Fahrzeuge lässt sich durch die Veränderung des Schwinkels über die Zeit ausdrücken. Führt z.B. das Vorderfahrzeug etwas schneller als das Folgefahrzeug, wird der Schwinkel über die Zeit kleiner. Michaels (1963) vermutete, dass sehr kleine Veränderungen des Schwinkels unbemerkt bleiben – bis sie eine bestimmte Schwelle erreichen. Die Schätzungen dieser Schwelle liegen zwischen 0,0006 rad/s (Michaels, 1963) und 0,003 rad/s (Hoffman & Mortimer, 1994).

Unterscheidet sich die relative Geschwindigkeit beider Fahrzeuge nur geringfügig, sodass diese Schwelle nicht überschritten wird – z.B. im Fall geringer Distanzen, wo sich die Geschwindigkeiten bereits stark angenähert haben – wird die Wahrnehmung von Geschwindigkeitsunterschieden vernachlässigt und der Fokus wird auf die Wahrnehmung der Veränderung von Distanzen verlagert (Hoffmann, 1966; Hoffmann & Mortimer, 1994; Mortimer, 1971). Das heißt: Veränderungen von Distanzen werden erst dann wahrgenommen, wenn sie sich deutlich von der ursprünglichen Distanz oder gewünschten Distanz unterscheiden, vorausgesetzt der Fahrer beobachtet das vorausfahrende Fahrzeug ausreichend lang ohne Unterbrechung (nach Hoffmann und Mortimer (1994) mindestens zwei Sekunden). Diese Schwelle wird auch *just noticeable difference* (JND) genannt und gibt die minimale proportionale Veränderung der Distanz an, die notwendig ist, um vom Menschen registriert zu werden. Bislang wurden Werte zwischen 0,1% und 10% angegeben (Brackstone & McDonald, 2000; Van Winsum, 1999).

Einige bereits etablierte Modelle beinhalten diese Komponenten der Wahrnehmungsschwellen (Fritzsche, 1994; Wiedemann & Reiter, 1992). Sie werden auch Action-Point-Modelle genannt (Brackstone & McDonald, 2000), weil erst bei Übertreten der Schwellen die Reaktion des Fahrers erfolgt. Bei Chen (1992) und Van Winsum (1999) wurde diese Schwelle des JND nicht mehr nur für die Distanzveränderung über die Zeit verwendet, sondern auch für die Abweichung von tatsächlicher Distanz zur Wunschdistanz. Bisherige Modelle mit Wahrnehmungsschwellen sollen in dieser Arbeit jedoch nicht mit aufgenommen werden. In Kapitel 3 wird hingegen eine Erweiterung des DVA-Modells um die zuvor erwähnten zwei Wahrnehmungsschwellen vorgestellt.

Mit den beiden Aspekten des Schwinkels und der Wahrnehmungsschwelle werden zunächst nur die Eingangssignale des Modells in den Blick genommen und versucht sie der menschlichen Wahrnehmung anzupassen. Dies ist nur ein Ansatzpunkt zur Erweiterung von

Fahrermodellen um den Faktor Mensch. Boer (1999) bemerkte z.B., dass bisherige Modelle unter der Prämisse formuliert sind, dass sie die Folgeaufgabe so gut wie möglich lösen. Dabei ist es unwahrscheinlich, dass dies zu jeder Zeit auch das Ziel des Menschen ist. In aktuelleren Veröffentlichungen wurden noch viele weitere Ansätze vorgeschlagen, Modelle hinsichtlich psychologischer Plausibilität zu formulieren (siehe dazu z.B. Hamdar, 2012; Treiber & Kesting, 2013), dies vorzustellen würde allerdings den Rahmen dieser Arbeit übersteigen.

2.4 Bisherige Vergleichsstudien

Die Entscheidung über die Güte eines Modells kann nicht anhand eines Wertes bestimmt werden. So gibt es keine Schwellen die besagen, ab wann ein Modell ausreichend gute oder sehr gute Vorhersagen macht. Vielmehr geht es um eine relative Einstufung der Güte im Vergleich von mehreren Modellen. Oder wie es MacCallum (2003) formulierte: „Of course, the investigator must still recognize that all of the models under consideration are imperfect, and the task is to find the one that is least wrong” (S. 130). Das Ziel eines Vergleichs ist es schlechtere Modelle zugunsten besserer Modelle verwerfen zu können, Modelle weiterzuentwickeln und sie adäquat einzusetzen. Die im Folgenden vorgestellten Studien haben einen solchen direkten Vergleich von Folgefahrtmodellen vorgenommen. Die jeweilige Auswahl der Modelle weist eine hohe Schnittmenge auf. Die Versuchsdesigns waren jedoch sehr unterschiedlich. Eine Gegenüberstellung dieser Studien zeigt, welche Faktoren bei einem Modellvergleich zu berücksichtigen sind. Zunächst soll aber ein Überblick gegeben werden, wie die hier vorgestellten Modelle in bisherigen Studien abschnitten.

Insgesamt kann festgehalten werden, dass das Gipps-Modell am häufigsten für Modellvergleiche herangezogen wurde. Darüber hinaus zählte es in allen hier erwähnten Vergleichsstudien zu den jeweils besten 50% aller Modelle. In einer Realfahrstudie von Panwai und Dia (2005) zeigte es sogar die besten Vorhersagen. Im Vergleich standen noch zwei weitere Modelle (Fritzsche, 1994; Wiedemann, 1974), die sich in die Gruppe der psychophysikalischen Modelle einordnen lassen und beide eine Wahrnehmungsschwelle beinhalten. Olstam und Tapani (2004) bemerkten jedoch, dass das Gipps-Modell vor allem dem Profil des Vorderfahrers ähnelt.

Das Modell von Helly wurde vorwiegend in früheren Jahren kalibriert und validiert. Trotz vergleichsweise guter Vorhersagen (Bekey, Burnham, & Seo, 1977; Rockwell, Ernst, & Hanken, 1968) wurde es in jüngerer Zeit mit wenigen Ausnahmen (Hoogendoorn, Hoogendoorn,

Brookhuis, & Daamen, 2010; Hoogendoorn, Ossen, & Schreuder, 2007) nicht beachtet. Gründe hierfür waren z.B. die unterschiedlichen Parameterschätzungen zwischen schnellen und langsamen Geschwindigkeiten, sodass die allgemeine Validität angezweifelt wurde (Brackstone & McDonald, 2000).

Das DVA-Modell ist in den meisten Vergleichsstudien von Folgefahrtmodellen noch unbeachtet geblieben. Lediglich in der ersten Veröffentlichung zu diesem Modell (Andersen & Sauer, 2007) wurde ein Vergleich mit dem Gipps-Modell angestellt, indem das DVA-Modell etwas präzisere Vorhersagen machte, sowohl für Daten eines Experiments im Simulator als auch einer Realfahrt. Die Realfahrtdaten stammen allerdings nur von einem Probanden während einer Autobahnfahrt, sodass die Aussagekraft dieser Ergebnisse eingeschränkt ist.

Im Folgenden werden Faktoren vorgestellt, von denen angenommen werden kann, dass sie Einfluss auf die geschilderten Ergebnisse der Vergleichsstudien nahmen und die folglich die Entwicklung des Versuchsdesigns dieser Arbeit mitbestimmten.

2.4.1 Individuelle Unterschiede

Brockfeld, Kühne und Wagner (2004) maßen die Daten von acht Fahrzeugen, die in einer Kolonne auf einer Teststrecke hintereinander herfuhrten. Das Vorderfahrzeug folgte dabei einem sinusförmigen Geschwindigkeitsprofil. Es konnte schließlich kein Modell identifiziert werden, dass den anderen eindeutig überlegen war. Auffälliger als die Modellunterschiede war hingegen die interindividuelle Varianz der Modellgüte. Der Unterschied der Modellgüte zwischen den Individuen (gemessen als Anteil fehlerhafter Vorhersagen in Prozent) betrug gemittelt ca. 5%, während zwischen den Modellen im Mittel nur ein Unterschied von ca. 2,5% lag.

Ossen und Hoogendoorn (2011) verwendeten ein anderes Vorgehen, um individuelle Unterschiede in der Vorhersagegüte von Folgefahrtmodellen deutlich zu machen. Für den Modellvergleich wurden zwei Stichproben herangezogen: An zwei verschiedenen Autobahnabschnitten wurde mittels Helikopterkamera das Folgefahrverhalten beobachtet. Sie bestimmten für jedes einzelne Individuum das Modell, das sein Verhalten am besten abbilden konnte. Tatsächlich wiesen auch diese Ergebnisse kein dominierendes Modell auf: Fünf von acht getesteten Modellen stellten für annähernd gleich viele Individuen die jeweils beste Verhaltensbeschreibung dar. Sie konnten diese Unterschiede weiterhin spezifizieren und zeigten exemplarisch, dass die Wunschdistanz für manche Individuen nicht durch einen linearen

Zusammenhang mit der Geschwindigkeit zutreffend beschrieben werden konnte – für andere Individuen dagegen schon. Doch selbst unter Letzteren unterschied sich die Stärke des Zusammenhangs deutlich.

2.4.2 Einfluss der Fahrsituation

In der gleichen Studie von Ossen und Hoogendoorn (2011) zeichnete sich zudem ein weiterer Einflussfaktor auf die Passung der Modelle ab: Zwischen den beiden Autobahnabschnitten, die beobachtet wurden, zeigten sich deutliche Unterschiede in der Güte der Modelle. Die Autoren führten das auf eine unterschiedliche Verkehrsdichte zurück.

Die Annahme, dass die Fahrsituationen auf die Vorhersagen von Modellen einen jeweils unterschiedlichen Effekt ausüben, wird durch den Vergleich der Studie von Ossen und Hoogendoorn mit einer weiteren Evaluationsstudie (Ranjitkar, Nakatsuji, & Kawamua, 2005) bestärkt. Beide Studien verglichen unter anderem das Chandler-Modell (Chandler et al., 1958) mit dem Gipps-Modell. Bei Ranjitkar et al. (2005) wurden Daten jedoch unter sehr kontrollierten Bedingungen erhoben. Zehn Fahrzeuge fuhren auf einer Teststrecke abseits des öffentlichen Verkehrs, während das Vorderfahrzeug einem vorgegebenen Fahrprofil folgte. Die Ergebnisse für das Chandler-Modell unterschieden sich zwischen den beiden Studien deutlich. Bei Ossen und Hoogendoorn (2011) war es eines der drei Modelle, welches klar hinter den anderen Modellen, wie z.B. dem Gipps-Modell, zurückblieb. In der Studie von Ranjitkar et al. (2005) zeigte das Chandler Modell sogar geringfügig niedrigere Abweichungen zum empirischen Verhalten als die anderen Modelle, und wies damit auch eine höhere Güte auf als das Gipps-Modell. Das traf sowohl auf die Vorhersagen für die Geschwindigkeit, als auch die Distanz zu, die in diesen zwei Studien beide betrachtet wurden. Die verschiedenen Versuchssituationen, könnten ein Grund für das unterschiedliche Ergebnis der beiden Studien sein.

Der Fall, dass das Chandler-Modell bei Ranjitkar et al. (2005) sowohl für Geschwindigkeit als auch Distanz die besten Vorhersagen machte, ist jedoch nicht immer gegeben. Das leitet über zum nächsten Kapitel und einer weiteren Erkenntnis aus bisherigen Vergleichsstudien über zu berücksichtigende Faktoren bei einem Modellvergleich: Die Wahl der Variable für die Vorhersagen, Distanz oder Geschwindigkeit.

2.4.3 Variable der Vorhersagen

Betrachtet man die weiteren Modelle, die bei Ranjitkar et al. (2005) verglichen wurden, fällt auf, dass die Variablen Distanz und Geschwindigkeit unterschiedliche Ranglisten der Modelle in Hinblick auf ihre Güte hervorbrachten. Auch bei Ossen (2008) wurde diese Diskrepanz zwischen den Variablen festgestellt. Hier entschied sich die Autorin ein *Multi-Criterion-Objective* zu bilden – eine kombinierte Variable aus Distanz und Geschwindigkeit, um einen universellen Vergleich der Modelle anstellen zu können. In beiden Studien waren die Vorhersagen für die Distanz schlechter, als die für die Geschwindigkeit. Bei Andersen und Sauer (2007) deutete sich dieser Unterschied ebenfalls an.

2.4.4 Gütemaß

Auch bei der Wahl des Gütemaßes, das die Vorhersagegüte der Modelle quantifiziert, gibt es mehrere Möglichkeiten. Das am häufigsten verwendete Maß zur Bemessung der Modellgüte ist RMSD (root mean square deviation) (Lewandowski & Farrell, 2011; Schunn & Wallach, 2005). Auch in den hier vorgestellten Vergleichsstudien wurde es angewandt (Andersen & Sauer, 2007; Panwai & Dia, 2005). Es ist die Wurzel des Mittelwerts der quadrierten Differenz zwischen Vorhersage und Messung:

$$RMSD = \sqrt{\sum_{j=1}^J \frac{(d_j - p_j)^2}{J}} \quad (8)$$

J ist die Gesamtanzahl der Datenpunkte, d ist die Messung zum Zeitpunkt j , und p die dazugehörige Modellvorhersage. Allerdings lässt sich RMSD nicht zwischen Variablen mit verschiedenen Einheiten vergleichen, da es die Einheit der jeweils eingesetzten Variablen annimmt. Brockfeld et al. (2004) und Ranjitkar et al. (2005) verwendeten deshalb einen *Percentage Error*. Dabei wird die mittlere absolute Abweichung zwischen vorhergesagten und beobachteten Daten an dem Mittelwert der beobachteten Daten relativiert, sodass das Gütemaß ein prozentualer Wert ist:

$$percentage\ error = \frac{\sum_{j=1}^J \frac{|d_j - p_j|}{J}}{\sum_{j=1}^J \frac{d_j}{J}} \quad (9)$$

Der Vorteil, den die Autoren bei einem prozentualen Gütemaß sehen, ist, dass das Maß einheitsunspezifisch ist. So konnten Ranjitkar et al. (2005) die Variablen Geschwindigkeit und Distanz nicht nur in Hinblick auf die relativen Unterschiede zwischen den Modellen vergleichen. Sie konnten dadurch auch direkt beurteilen, dass für die Geschwindigkeit bessere Vorhersagen gemacht wurden, als für die Distanz. Bei Ossen (2008) und Ossen und Hoogendoorn (2011) wurde mit der gleichen Absicht, ein einheitsunspezifisches Maß zu verwenden, das Maß *Theils' u* eingesetzt. Es kann als Anpassung von RMSD angesehen werden, da RMSD hier zusätzlich am quadratischen Mittel der beobachteten als auch der vorhergesagte Variable relativiert wird:

$$Theils' u = \frac{\sqrt{\sum_{j=1}^J \frac{(d_j - p_j)^2}{J}}}{\sqrt{\sum_{j=1}^J \frac{(d_j)^2}{J}} + \sqrt{\sum_{j=1}^J \frac{(p_j)^2}{J}}} \quad (10)$$

Andersen und Sauer (2007), sowie Schunn und Wallach (2005) schlagen noch ein weiteres Gütemaß vor: Den Korrelationskoeffizienten (r) nach Pearson. Mit r wird bemessen, inwiefern die Modellvorhersagen in einem linearen Zusammenhang zu den beobachteten Daten stehen. Somit gibt dieses Maß noch einen anderen Aspekt der Passung zwischen Vorhersage und empirischen Daten wieder, nämlich den Zusammenhang anstelle der absoluten Abweichung.

Die Frage, ob auch das Gütemaß Einfluss auf das Ergebnis eines Modellvergleichs nimmt, stellte sich auch Ossen (2008). Sie verglich mehrere Gütemaße, darunter *Theils' u* und RMSD. Hier stellte sich jedoch heraus, dass auch bei verschiedenen Datensätzen mit unterschiedlich großem Messfehler die Gütemaße nahezu gleiche Parameterschätzungen hervorbrachten und somit der Modellvergleich jeweils gleich ausfiel.

Insgesamt machen die genannten Studien schließlich deutlich, dass eine Vielzahl an Faktoren Einfluss darauf nimmt, wie die Modelle in Hinblick auf ihre Vorhersagegüte zueinander abschneiden. Dabei ist es nicht nur die Versuchssituation, die Einfluss auf das Fahrverhalten der Probanden nimmt und damit die Vorhersagen einiger Modelle begünstigt und andere

benachteiligt. Schon allein die Frage, für welche Variable die Modellvorhersagen betrachtet werden, kann einen Unterschied bedeuten. Hinzu kommt, dass zwischen Individuen große Unterschiede im Fahrverhalten zu herrschen, sodass potentielle Unterschiede der Modelle leicht in der individuellen Varianz verloren gehen.

3 Fragestellungen

In der vorliegenden Arbeit wird ein Vergleich von sowohl etablierten als auch neueren Folgefahrtmodellen vorgenommen. Besonderes Augenmerk liegt dabei auf der Frage, inwiefern psychologisch plausible Modelleigenschaften – wie die Nutzung des Seh winkels oder einer Wahrnehmungsschwelle – die Güte der Modellvorhersage beeinflussen können. Aus diesem Grund wird hier mit dem DVA-Modell ein bislang noch wenig beachtetes Modell mit anderen verglichen, das als Eingangssignal den Seh winkel nutzt. Der Vorteil des DVA-Modells als Vergleichsmodell liegt außerdem darin, dass es sich von seinem Vorgänger-Modell von Helly nur in der Nutzung des Seh winkels unterscheidet und ein direkter Vergleich beider Ansätze Aufschluss darüber gibt, ob diese Veränderung das Modell verbessert oder nicht. Um auch den Einfluss einer Wahrnehmungsschwelle im Modell auf dessen Vorhersagegüte systematisch überprüfen zu können, wird hier eine Erweiterung des DVA-Modells vorgenommen, anstatt bereits etablierte Modelle (Benz, 1994; Fritzsche, 1994; Wiedemann & Reiter, 1992) für einen Vergleich heranzuziehen.

Mit der *just noticeable difference* für die Abweichung von der Wunschdistanz, wie sie Chen (1992) und Van Winsum (1999) vorschlagen, sowie der Schwelle für relative Geschwindigkeiten, liegen Wahrnehmungsschwellen für zwei Eingangssignale vor, die im DVA-Modell enthalten sind. Das DVA-Modell lässt sich also um diese zwei Schwellen ergänzen. Der erste Term des DVA-Modells nimmt den Wert null an und nimmt damit keinen Einfluss auf das Ausgangssignal des Modells, sobald die Abweichungen der tatsächlichen Distanz von der Wunschdistanz kleiner als 10% ist. Für den zweiten Term ist das der Fall, wenn die Veränderung des Seh winkels pro Sekunde 0,0006 rad nicht überschreitet. Treten beide Fälle ein, würde weder eine Beschleunigung noch eine Bremsung durchgeführt werden. Da es unwahrscheinlich ist, dass der Fahrer die gefahrene Geschwindigkeit exakt halten kann, soll jeweils bei Unterschreiten einer der beiden Schwellen nicht der Wert null angenommen werden, sondern lediglich eine fünffache

Verkleinerung durchgeführt werden. Diese Erweiterung des DVA-Modells soll im Folgenden als DVA-PT (für perception threshold) bezeichnet werden.

Mit den Modellen Helly, DVA und DVA-PT liegen somit drei Entwicklungsstufen eines Modells vor. Jede Entwicklungsstufe enthält eine zusätzliche psychologisch plausible Komponente. Der Modellvergleich wird um das Modell von Gipps ergänzt, da es das am häufigsten validierte Folgefahrmodell ist und gleichzeitig zu den Modellen gehört, welche die präzisesten Vorhersagen vorweisen können (Olstam & Tapani, 2004; Ossen & Hoogendoorn, 2011; Panwai & Dia, 2005).

In dieser Arbeit soll der Modellvergleich unter Berücksichtigung jener Faktoren erfolgen, von denen anzunehmen ist, dass sie zu unterschiedlichen Ergebnissen eines Modellvergleichs führen. Diese sind: Der Einfluss individueller Unterschiede, der Fahrsituation und die betrachtete Variable (Geschwindigkeit und Distanz). Um dem starken Einfluss individueller Unterschiede zu begegnen, ist vor allem die Wahl einer angemessenen Stichprobe entscheidend, sodass potentielle Effekte zwischen Modellen und anderen Einflussfaktoren überhaupt entdeckt werden können. Bei Ossen und Hoogendoorn (2011) ließ das Versuchsdesign z.B. nur kurze ca. vier bis zehn minütige Beobachtungen zu, sodass pro Individuum wenige Daten zur Verfügung standen und die Varianz zwischen Individuen auch durch intraindividuelle Schwankungen hätte hervorgerufen werden können. Brockfeld et al. (2004) konnten auf längere Fahrten pro Individuum zurückgreifen (insgesamt ca. 80 Minuten). Die Dominanz der individuellen Unterschiede könnte hierbei jedoch weniger durch die starken individuellen Unterschiede, als vielmehr durch die geringen Unterschiede der Modellvorhersagen verursacht worden sein.¹ Das Fahrprofil des Vorderfahrzeugs folgte einem vorgegebenen, sinusförmigen Verlauf. Bei dem Vergleich zwischen Gipps- und DVA-Modell von Andersen und Sauer (2007), zeigten sich im Simulator-Experiment mit vorgegebenem Fahrprofil ebenfalls wesentlich kleinere Modellunterschiede als im Realfahrtexperiment. Die Stärke bzw. Schwäche von Modellen zeigt sich womöglich erst in ihrer Performanz bei der Vorhersage von natürlichem, komplexem Fahrverhalten. Aus diesen

¹ Da in den Studien von Ossen und Hoogendoorn (2011) und Brockfeld et al. (2004) mit unterschiedlichen Gütemaßen gearbeitet wurde, ist ein direkter Vergleich der Größe der individuellen Unterschiede nicht möglich.

Gründen wurden in dieser Arbeit Fahrdaten von zwölf Probanden jeweils über ca. 45 Minuten gemessen, die zudem im alltäglichen Straßenverkehr erhoben wurden (mehr dazu in Kapitel 4).

In den hier erwähnten Vergleichsstudien wurde weiterhin der Einfluss unterschiedlicher Fahrsituationen auf die Vorhersagegüte von Modellen hervorgehoben. Leicht zu identifizierende Fahrsituationen, die sich unterscheiden und eine praktisch umsetzbare experimentelle Manipulation bedürfen, sind z.B. Landstraßen, Autobahnen und Strecken durch städtische Gebiete. Sie unterscheiden sich in der maximal erlaubten Reisegeschwindigkeit und der Variabilität der möglichen Reisegeschwindigkeit, dem umgebenden Verkehr (Anzahl der Fahrbahns Spuren, Abbiegespuren, Ampeln), den umgebenden Kontext (Menschen, Häuser, Bepflanzung) und den Lichtverhältnissen. Aus diesem Grund wird bei diesem Modellvergleich eine Trennung zwischen den Streckentypen Autobahn, Landstraße und Stadt vorgenommen, um zu testen ob der Streckentyp auf die Vorhersagegüte der vier Modelle einen jeweils unterschiedlichen Effekt ausübt. Die erste Fragestellung lautet somit:

1. *Interagiert der Faktor Modell und der Faktor Streckentyp in Hinblick auf die Vorhersagegüte?*

Je nachdem ob oder welche Art der Interaktion vorliegt, kann der Einfluss des Streckentyps auf die Modellvorhersagen global untersucht werden. Die zweite Fragestellung lautet demnach:

2. *Unterscheiden sich die Modellvorhersagen für die drei Streckentypen Autobahn, Landstraße und Stadt?*

Genauso können die Modelle untereinander ungeachtet der Streckentypen verglichen werden, je nach vorliegender Interaktion. Hier ist die Fragestellung konkreter:

3. *Zeigen die psychologisch plausiblen Modelle (DVA und DVA-PT) die besseren Vorhersagen, als die psychologisch unplausiblen Modelle (Helly und Gipps)?*

Entsprechend den Erkenntnissen aus den bisherigen Vergleichsstudien wird die Auswertung dieser Fragestellungen sowohl für Distanz und Geschwindigkeit vorgenommen. Auf eine kombinierte Variable aus Geschwindigkeit und Distanz wie sie bei Ossen (2008) und Ossen und Hoogendoorn (2011) eingesetzt wurde, soll hier nicht zurückgegriffen werden. Die

Ergebnisse von Ranjitkar et al. (2005) machen deutlich, dass der Modellvergleich jeweils unterschiedlich ausfällt, je nachdem welche Variable betrachtet wird. Diese Effekte würden bei einem kombinierten Maß verdeckt werden. Mit einem einheitsunspezifischen Gütemaß, wie es in Kapitel 2.4.4 beschrieben wurde, können die beiden Variablen direkt verglichen werden. Die in Kapitel 2.4.4 beschriebenen einheitsunspezifischen Maße percentage error und Theils'u haben allerdings Nachteile: Die Abweichungen der Modellvorhersagen werden am arithmetischen Mittel bzw. quadratischen Mittel der empirischen Daten der jeweiligen Variable standardisiert. Es ist jedoch möglich, dass sich die Variablen in mehr Eigenschaften als einem Durchschnittswert unterscheiden. Ein geeigneteres Maß stellt deshalb der Korrelationskoeffizient r nach Pearson dar (Schunn & Wallach, 2005). Dieser wurde auch von Andersen und Sauer (2007) zum Vergleich des DVA-Modells mit dem Gipps-Modell verwendet. So können die Ergebnisse dieser Studie direkt mit denen von Andersen und Sauer (2007) verglichen werden. Um dennoch die absolute Abweichung der Modelle bemessen zu können und damit in der Tradition bisheriger Vergleichsstudien zu bleiben, wird zusätzlich das gängige Maß RMSD verwendet. RMSD ist leicht zu interpretieren, da es ein Maß für die absolute Abweichung zwischen Vorhersagen und empirischen Daten ist. Durch das Quadrieren der Differenz zwischen Messung und Vorhersage, werden große Abweichungen hier stärker gewichtet und die Modellpassung eher unterschätzt. Das macht den RMSD zu einem geeigneten Maß für Datensätze, die mit Messfehlern behaftet sind (Schunn & Wallach, 2005), wie sie in dieser Studie angenommen werden müssen. Mit RMSD für die absolute Abweichung der Modellvorhersagen und r für den Zusammenhang zwischen Vorhersagen und empirischen Daten, liegen zwei Maße vor, die sich in ihrer Beschreibung der Güte von Modellen ergänzen. Deshalb werden beide Gütemaße zur Beantwortung der Fragestellungen herangezogen.

4 Methode

4.1 Unabhängige Faktoren

Es wurden vier Folgefahrtmodelle (Helly, DVA, DVA-PT, Gipps) anhand ihrer Vorhersagegüte miteinander verglichen. Für jedes Individuum wurden mit allen vier Modellen Vorhersagen generiert. Somit ist der Faktor Modell ein Innersubjektfaktor.

Der zweite Faktor ist der Faktor Streckentyp mit drei Ausprägungen (Autobahn, Landstraße, Stadt). Auch dieser wurde als Innersubjektfaktor angelegt.

4.2 Abhängige Faktoren

Die abhängige Variable ist die Güte der Modellvorhersagen der einzelnen Modelle. Sie wurde hier durch zwei Maße quantifiziert: RMSD und den Korrelationskoeffizient r , nach Pearson. Zudem wurden sie für die Vorhersagen der Distanz und der Geschwindigkeit bestimmt, sodass letztlich vier Gütekennwerte (RMSD für Distanz, RMSD für Geschwindigkeit, r für Distanz, r für Geschwindigkeit) vorlagen. Pro Individuum und Streckentyp wurden für jedes Modell diese vier Gütekennwerte errechnet, sodass pro Gütemaß und Variable eine Verteilung von 12 Gütekennwerten vorlag, die inferenzstatistische Analysen ermöglichte. Tabelle 1 verdeutlicht das Versuchsdesign.

Tabelle 1

Versuchsdesign

Modell Streckentyp	Helly	DVA	DVA-PT	Gipps
Autobahn	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r
Landstraße	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r
Stadt	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r	Distanz mit RMSD Geschw. mit RMSD Distanz mit r Geschw. mit r

Anmerkung. Die erste Zeile benennt die vier Stufen des Faktors Modell, die erste Spalte die drei Stufen des Faktors Streckentyp. In den Zellen ist die Modellgüte als abhängige Variable angegeben, in Form der vier Kombinationen aus zwei Gütemaßen (RMSD, r) und zwei Variablen (Distanz, Geschwindigkeit). Für jede Kombination liegen pro Zelle zwölf Datenpunkte vor.

Die Anzahl freier Parameter in einem Modell, sollte im Gütekennwert berücksichtigt werden. Je mehr freie Parameter ein Modell besitzt, desto mehr Möglichkeiten hat es auf einen Datensatz passend kalibriert zu werden und folglich bessere Vorhersagen zu machen. In der Literatur werden Korrekturfaktoren vorgeschlagen, die den Gütekennwert eines Modells entsprechend der Anzahl seiner freien Parameter korrigieren (Lewandowsky & Farrell, 2011).

Wie groß der Gewinn in der Vorhersagegüte durch Hinzunahme eines weiteren freien Parameters ist, ist von Modell zu Modell unterschiedlich und kann schwer beziffert werden. Deshalb ist die Wahl eines Korrekturfaktors meist willkürlich (Ossen, 2008). Das Helly-Modell hat mit fünf Parametern die meisten freien Parameter, das Gipps- und die DVA-Modelle haben jeweils vier. Die Modelle unterscheiden sich also nur geringfügig in der Anzahl ihrer freien Parameter. Deshalb wurde hier auf einen Korrekturfaktor verzichtet.

4.3 Modellkalibrierung

Bevor die Vorhersagegüte der Modelle bestimmt werden kann, müssen zunächst Werte für die freien Parameter der Modelle gefunden werden, bei denen das Modell die bestmöglichen Vorhersagen produziert. Das heißt, der Gütekennwert (sei es RMSD oder r) erreicht bei diesen Parameterwerten sein Optimum. Um diese Werte zu finden müssten theoretisch mit allen möglichen Parameterwerten Modellvorhersagen generiert werden. Jene Werte, die die geringste Abweichung aufweisen, würden ausgewählt werden. Da sich die möglichen Parameterwerte auf einer kontinuierlichen Skala befinden, ist die Anzahl möglicher Parameterkombinationen unendlich groß. Somit ist es unmöglich alle Parameterkombinationen abzubilden, um jene mit der geringsten Abweichung zu finden. Suchalgorithmen verkürzen die Suche, leisten dafür aber nur noch eine Schätzung der besten Parameterwerte und keine sichere Bestimmung. Bei dieser Art der Parameteroptimierung werden ausgehend von jeweils einem Startwert pro Parameter, die Parameterwerte sukzessive variiert. Verkleinert sich dabei die Abweichung, wird die Richtung der Variation weiter verfolgt. Andernfalls wird eine andere Richtung eingeschlagen. Verschiedene Suchalgorithmen unterscheiden sich in der Wahl der Regel, nach der die Parameterwerte variiert werden. Hier wurde der Algorithmus L-BFGS-B verwendet (Byrd, Lu, Nocedal, & Zhu, 1995). Im Vergleich zu anderen Algorithmen ist er sehr schnell, was angesichts der Datenmengen einen Vorteil darstellt. Weiterhin bietet er die Möglichkeit Grenzwerte für die Parameterschätzung anzugeben, was hier genutzt wurde. Die Kalibrierung wurde mit dem Gütemaß RMSD durchgeführt. Für jedes Individuum und jeden Streckentyp wurden eigene Parameterwerte generiert.

4.3.1 Parametergrenzen

Einige der freien Parameter sollen laut Modelldefinition bestimmte Werte nicht annehmen. Beim Gipps-Modell sind alle freien Parameter inhaltlich bedeutsam. Es wäre z.B. unplausibel wenn der Parameter b_{max} (maximale Bremsung) einen Wert unter -6 m/s^2 annehmen würde, vorausgesetzt es werden Unfälle ausgeschlossen. Die konkreten Wertebereiche für das Gipps-Modell wurden von Ossen und Hoogendoorn (2011) übernommen. Allerdings wurde der Wert null bei den Wertegrenzen für Reaktionszeit T_r , b_{max} und b_{est} durch Werte nahe null ersetzt, da es unplausibel wäre, wenn diese drei Parameter den Wert null annähmen.

Tabelle 2

Modellparameter mit ihren Wertegrenzen und Beschreibungen

Modell	Parameter	Grenzen	Beschreibung
Helly	T_r	[0,2; 4]	Reaktionszeit
	k	[> 0]	Gewicht für die Abweichung von der Geschwindigkeit des Vorderfahrzeugs
	j	[> 0]	Gewicht für die Abweichung von der gewünschten Distanz
	f	[> 0]	Gewicht für die Stärke des Zusammenhangs von Geschwindigkeit und Wunschdistanz
	d_{min}	[> 0]	minimaler Abstand, den der Fahrer des Folgefahrzeugs nicht unterschreiten möchte/Abstand bei Stillstand
DVA / DVA-PT	T_r	[0,2; 4]	Reaktionszeit
	k	[< 0]	Gewicht für die Abweichung von der Geschwindigkeit des Vorderfahrzeugs
	j	[> 0]	Gewicht für die Abweichung vom gewünschten Schwinkel
	d_{time}	[> 0]	gewünschter Abstand zum Vorderfahrzeug in Zeit
Gipps	T_r	[0,2; 4]	Reaktionszeit
	b_{max}	[-6; -0,01]	stärkste Bremsung, die der Fahrer des Folgefahrzeugs vornehmen möchte
	b_{est}	[-6; -0,01]	stärkste Bremsung, die der Fahrer des Vorderfahrzeugs vornehmen möchte
	d_{min}	[1,5; 15]	minimaler Abstand, den der Fahrer des Folgefahrzeugs nicht unterschreiten möchte/Abstand bei Stillstand

Anmerkung. Aufgeführt sind alle freien Parameter der Modelle. Die Parametergrenzen bestimmen, in welchem Wertebereich der Wert für den freien Parameter liegen darf.

Auch für die Parameter j und k des DVA und Helly-Modells, die lediglich abstrakte Gewichte für die Modellterme darstellen, gibt es Wertegrenzen, da die Modelle ansonsten nicht so funktionieren wie es beabsichtigt ist. Am Beispiel des DVA-Modells: Ist die Veränderungsrate des Sehwinkels positiv, bedeutet es das Vorderfahrzeug fährt langsamer als das folgende Fahrzeug. Eine plausible Vorhersage würde eine negative Beschleunigung (also Bremsung) sein. Somit sollte das Gewicht des Terms ein negatives Vorzeichen haben. Die Reaktionszeitparameter des Helly-Modells und der DVA-Modelle erhielten aus Gründen der Vergleichbarkeit die gleichen Wertegrenzen wie das Gipps-Modell (genauso wie d_{min} für das Helly-Modell.) Alle Beschränkungen der Parameter sind in Tabelle 2 aufgeführt.

4.3.2 Startparameter

Bei der Wahl der Startparameter wurde zunächst versucht auf Parameterschätzer aus vorherigen Studien zurückzugreifen. Dies konnte für j , k und d_{min} des Helly-Modells und für j und k der DVA-Modelle gemacht werden (siehe Tabelle 3).

Tabelle 3

Startparameter

Modell	Parameter	Startwerte
Helly	T_r	1
	k	0,5
	j	0,125
	f	0,9
	d_{min}	6
DVA / DVA-PT	T_r	1
	k	-800
	j	0,02
	d_{time}	2
Gipps	T_r	1
	b_{max}	-3
	b_{est}	-3
	d_{min}	3

Anmerkung. Die Startwerte, werden dem Optimierungsalgorithmus L-BFGS-B übergeben. Von dort aus beginnt die Suche nach den optimalen Werten.

Der Parameter d_{time} wurde bei Andersen und Sauer (2007) nicht kalibriert. Hier wurden die für Autofahrer empfohlenen zwei Sekunden gewählt (Shinar, 2007). Gipps (1981) kalibrierte sein Modell nicht, sondern setzte lediglich inhaltlich plausible Werte ein. Als Startwerte wurden deshalb die Mitten der Parametergrenzen verwendet. Alle Startparameter sind in Tabelle 3 aufgelistet.

4.4 Stichprobe

Die Stichprobe umfasste zwölf Teilnehmer. Alle eingeladenen Teilnehmer absolvierten den kompletten Versuch. Es gab keinen vorzeitigen Abbruch und nachträglich musste kein Teilnehmer ausgeschlossen werden. Voraussetzung der Teilnahme war der Besitz eines Führerscheins. Es nahmen fünf Frauen und sieben Männer im Alter von 23 bis 32 Jahren mit einem Durchschnittsalter von 27,36 Jahren ($SD = 3,14$) teil. Die Teilnehmer besaßen ihren Führerschein im Mittel seit 9,18 Jahren ($SD = 2,41$) und fuhren nach eigener Einschätzung im letzten Jahr durchschnittlich 8875 km, wobei die Unterschiede zwischen den Teilnehmern mit einer Standardabweichung von 6377,45 km groß sind. Unter den zwölf Teilnehmern sind nur drei, die in einer typischen Arbeitswoche täglich fahren. Drei weitere fahren an ein bis zwei Tagen. Unter diesen sechs regelmäßigen Fahrern wird durchschnittlich in der Stadt am häufigsten gefahren (42%), gefolgt von Autobahnfahrten (36%) und Landstraßenfahrten (22%). Ihre Fahrerfahrung im Vergleich zu Freunden und Bekannten stuften sie auf einer Skala von -3 (viel weniger Fahrerfahrung) bis +3 (viel mehr Fahrerfahrung) auf durchschnittlich 1,33 (1,03) ein, während keiner der Teilnehmer angab, weniger Fahrerfahrung zu besitzen als Menschen in ihrem Umfeld.

Die Probanden wurden über den E-Mail Verteiler des Deutschen Zentrums für Luft- und Raumfahrt und des Studiengangs Psychologie der TU Braunschweig rekrutiert. Für die Teilnahme erhielten die Probanden eine Aufwandsentschädigung von 25 Euro.

4.5 Durchführung

Die Erhebungen starteten jeweils auf dem Gelände des Deutschen Zentrums für Luft- und Raumfahrt (DLR) in Braunschweig. Die Teilnehmer wurden zunächst über den Zweck und Verlauf der Studie aufgeklärt. Die Instruktion der Aufgabe lautete dem vorausfahrenden Fahrzeug zu folgen. Dabei waren die Teilnehmer aufgefordert stets so zu fahren, dass sie sich

sicher fühlen, sodass die Sicherheit der Folgeaufgabe immer vorrangig war. Es wurde keine Vorgabe gemacht, wie groß der zu haltende Abstand sein soll, wie es in Simulationsstudien oft der Fall ist. Da im öffentlichen Straßenverkehr gefahren wurde, wäre eine Vorgabe aus Sicherheitsgründen nicht zu vertreten gewesen, insbesondere weil anzunehmen ist, dass sich der persönliche Sicherheitsabstand zwischen Autobahn- und Stadtfahrt stark unterscheidet. Zum anderen war somit die Versuchssituation der alltäglichen Fahrsituation ähnlicher. Die Teilnehmer fuhren zur Eingewöhnung mit dem Fahrzeug zunächst über das Gelände des Deutschen Zentrums für Luft- und Raumfahrt. Während der kompletten Versuchsfahrt, saß die Versuchsleiterin neben den Teilnehmern im Folgefahrzeug, sodass Fragen gestellt werden konnten. Ansonsten weder gesprochen noch Radio gehört, um das Verhalten des Fahrers nicht zusätzlich zu beeinflussen. Nach Beenden der Versuchsfahrt beantworteten die Teilnehmer demographische Fragen, sowie Fragen zu ihrer Fahrerfahrung.

Die Versuchsfahrten fanden im Mai und Juni 2014 statt. Um möglichst wenig Verkehr vorzufinden, wurde ausschließlich an Sonn- und Feiertagen erhoben. Damit wurde das Risiko minimiert, dass sich andere Fahrzeuge aufgrund der engen Verkehrssituation zwischen die beiden hintereinanderher fahrenden Versuchsfahrzeuge einreihen mussten.

4.6 Versuchsmaterial

Für die Versuchsfahrten wurden zwei Fahrzeuge benötigt. Das vorausfahrende Fahrzeug war ein Audi A6 Kombi mit einer Breite von 1,81 m. Das Folgefahrzeug, das von den Probanden geführt wurde, war ein VW T5 Multivan mit Automatikgetriebe (siehe Abbildung 2). Die automatische Schaltung des Folgefahrzeugs hatte den Vorteil, dass das Fahrverhalten der Teilnehmer in Hinblick auf die Abstandshaltung nicht zusätzlich durch Schaltvorgänge beeinflusst wurde. Wenn beim Schaltvorgang für kurze Zeit kein Gang eingelegt ist, kann die Geschwindigkeit in diesem kurzen Augenblick nicht geregelt werden.

Das Folgefahrzeug war mit Messtechnik ausgestattet, da das Fahrverhalten des Probanden die relevanten Messdaten waren. (Lediglich das Geschwindigkeitsprofil des Vorderfahrzeugs ist für die Analysen notwendig. Dieses konnte durch die Messtechnik des Folgefahrzeugs bestimmt werden.)



Abbildung 2. Das mit Messtechnik ausgestattete Fahrzeug, das von den Probanden geführt wurde. Unter der Stoßstange ist der Radar zu sehen.

Die Messtechnik bestand aus einer sogenannten NDS-Plattform. Dies ist eine Datenplattform, die im Rahmen des Projekts „BAST-NDS“ des Deutschen Zentrums für Luft- und Raumfahrt und der Bundesanstalt für Straßenwesen entwickelt wurde. Sie dient als Messwerkzeug für die Forschungsmethode der „Naturalistic Driving Studies“ (NDS), die nicht-reaktive Messungen von Fahrverhalten im alltäglichen Straßenverkehr vornehmen. Die Plattform besteht aus den drei folgenden Komponenten: 1. Sensoren zum Erfassen der Fahrdaten 2. einer Datenloggereinheit zum Ablegen der Daten auf einen Speicher und 3. einem CAN-Bus-System zum effizienten Übertragen der Daten von den Sensoren zur Loggereinheit. Die für diese Studie relevanten Sensoren waren zum einen ein GPS-Empfänger zur Ermittlung von Positions- und Geschwindigkeitsdaten, aus denen später auch noch Beschleunigungsdaten errechnet wurden. Weiterhin wurden zur Messung der Distanz zum Vorderfahrzeug Radardaten verwendet. Der Radar war an der Fahrzeugfront des Folgefahrzeugs montiert. Durch die Kombination aus GPS- und Radardaten konnte ebenfalls die Geschwindigkeit des Vorderfahrzeugs bestimmt werden. Im Fahrzeuginneren waren zusätzlich vier Videokameras angebracht, die das Geschehen vor und hinter dem Fahrzeug sowie vom Inneren des Fahrzeugs mit Blick auf den Fahrer aufnahmen. Mithilfe dieser Videoaufzeichnungen konnten im Nachhinein die genauen Zeiten verschiedener

Vorkommnisse (z.B. das Einordnen fremder Fahrzeuge zwischen die Testfahrzeuge) ermittelt und anschließend in den Daten ausgeschlossen werden.

4.6.1 Technische Details

Die zeitliche Auflösung der GPS-Daten betrug 200 ms. Die Geschwindigkeit konnte auf 0,001 km/h genau aufgezeichnet werden – die Positionsdaten in Form der Breiten und Längengrade auf 0,0000001°. Die zeitliche Auflösung des Radars betrug 40 ms. Die Distanz wurde mit einer Genauigkeit von 0,032 m gemessen. Da die Geschwindigkeit des Vorderfahrzeugs durch eine Kombination aus GPS und Radardaten ermittelt wurde, weist diese Variable mit 0,36 km/h Genauigkeit eine geringere Präzision auf, als die reinen GPS-Daten für das Folgefahrzeug.

Die Messdaten wurden auf CF (Compact Flash) Karten gespeichert und mithilfe eines Logfile Importers (Waigand, 2011) auf einem Datenserver abgelegt, von wo sie in die Statistik-Software R überführt werden konnten.

4.6.2 Versuchsstrecke

Die Versuchsstrecke führte durch die Stadt Braunschweig und ihre Umgebung. Zur Umsetzung des Faktors Streckentyp verlief die Strecke sowohl über die Autobahn (A2 zwischen Kreuz Wolfsburg und Kreuz Braunschweig-Nord), Landstraße (B4 zwischen Kreuz Braunschweig-Nord und Meine) und durch die Stadt (Gifhorner Straße und den Braunschweiger Stadtring). Die Strecke war insgesamt 72 km lang. Start und Ziel war der DLR-Standort. Eine Karte mit der gefahrenen Strecke ist in Abbildung 3 zu sehen. Eine Anforderung an den Verlauf der Strecke waren möglichst gerade Streckenabschnitte, weil Kurven einschließlich Autobahnauffahrten und -abfahrten nachträglich herausgenommen werden mussten. Das hatte zwei Gründe: Zum einen wird das Vorderfahrzeug in Kurven meist nicht mehr vom Radar des Folgefahrzeugs erfasst, sodass in diesen Momenten keine Daten zum Abstand des Fahrzeugs vorliegen. Zum anderen sind die hier genutzten Folgefahrtmodelle bisher nur für gerade Streckenabschnitte konzipiert und getestet worden. Folgefahrverhalten in Kurven unterliegt

womöglich anderen Einflussfaktoren und stellt damit eine eigene Forschungsfrage dar, die hier nicht berücksichtigt wurde.




Abbildung 3. Markiert ist die im Versuch gefahrene Strecke über die Autobahn, Landstraße und durch die Stadt; Datenquelle der Karte: Stadt Braunschweig – Open GeoData, 2014, Lizenz: dl-de/by-2-0 (die markierte Strecke und die Bezeichnungen wurden nachträglich hinzugefügt)

4.7 Datenanalyse

Die Datenaufbereitung und Modellkalibrierungen wurden mit der Software R (Version 3.1.0) durchgeführt. Dafür wurden folgende Pakete verwendet: data.table, plyr, RODBC, stringr, fitDRC, zoo, reshape2. Für die statistische Auswertung wurde das Statistikprogramm SPSS (Version 22) benutzt.

4.7.1 Datenaufbereitung

Da die Messtechnik auch Artefakte produzieren kann, wurden die Sensordaten zunächst auf Plausibilität geprüft. Extremwerte und starke Messwertsprünge von einer Zeiteinheit zur nächsten wurden anschließend ausgeschlossen. Für die Geschwindigkeitsmessungen lagen die tolerierten Werte zwischen null und 140 km/h. In Fällen, in denen die Messwerte innerhalb einer Sekunde um mehr als 25 km/h (7 m/s) anstiegen, wurden sie ebenfalls ausgeschlossen einschließlich der Messwerte jeweils 600 ms vor und nach einem solchen Sprung. Die tolerierten Distanzmessungen des Radars lagen zwischen 1,5 m und 200 m. Messwertsprünge wurden ab 50 m pro Sekunde ausgeschlossen, wieder einschließlich der umliegenden Werte 600 ms vor und nach dem Sprung. Neben den artifiziellen Werten werden weitere Passagen ausgeschlossen. So kam es in wenigen Fällen vor, dass sich ein fremdes Fahrzeug zwischen die beiden Versuchsfahrzeuge einfädelt oder das Folgefahrzeug den Anschluss an das Vorderfahrzeug verlor (z.B. an einer roten Ampel). Solche Ereignisse wurden ebenfalls in den Daten ausgeschlossen. Der Vorteil bei Datensätzen, die mit hoher zeitlicher Auflösung aufgezeichnet werden, ist die Möglichkeit kurze Abschnitte fehlender Werte durch Interpolation zu ersetzen. Hier wurde eine lineare Interpolation verwendet: Anhand des letzten validen Wertes vor einer Gruppe fehlender Werte und dem nächsten validen Wert wird eine lineare Funktion gebildet, die die fehlenden Werte zwischen ihnen ersetzt. Interpoliert wurden Abschnitte fehlender Werte, die bis zu 40 Sekunden lang waren.

Weiterhin sind GPS-Aufzeichnungen nicht komplett stabil, sodass sie nach oben und unten hin etwas von den tatsächlichen Werten abweichen. Aus diesem Grund wurden die Geschwindigkeitsdaten des GPS geglättet, indem jeder Wert durch den Mittelwert der ihn umgebenden sechs Werte ersetzt wurde.

Nach Bereinigung der Daten wurden schließlich neue Variablen berechnet, die nicht direkt gemessen werden konnten, aber als Eingangssignale für die Modelle gebraucht wurden. Zunächst wurde die Beschleunigung durch die Ableitung der Geschwindigkeit des Folgefahrzeugs ermittelt. Besonders für diesen Schritt war es wichtig, die Geschwindigkeitsdaten zuvor zu glätten, da ansonsten eine Kumulierung des Messfehlers stattfindet. Als nächstes wurde die Geschwindigkeit und Beschleunigung des Vorderfahrzeugs ermittelt. Wie bereits erwähnt, gibt das Messsystem die relative Geschwindigkeit zum Vorderfahrzeug aus, die es aus den GPS- und Radardaten ermittelt. Somit konnte die Geschwindigkeit des Vorderfahrzeugs durch die

Differenz aus relativer Geschwindigkeit und Geschwindigkeit des Folgefahrzeugs berechnet werden. Auch die Streckentypen Autobahn, Landstraße, Stadt, sowie alle restlichen Streckenabschnitte, die nicht in die Analyse miteingehen sollten, mussten nachträglich den entsprechenden Fahrdaten zugeordnet werden. Diese Zuordnung konnte anhand der gemessenen GPS-Positionsdaten vorgenommen werden. Dazu wurden zunächst die Koordinaten der Anfangs- und Endpunkte relevanter Streckenabschnitte ermittelt. Ein Abgleich dieser Koordinaten und der Positionsdaten des Messfahrzeugs gab Aufschluss darüber, wann der Fahrer in die jeweiligen Streckenabschnitte eingetreten ist oder sie verlassen hat. Die letzte zu berechnende Variable war der Sehwinkel, den das Vorderfahrzeug aus der Perspektive des Folgefahrzeugs einnimmt. Diese Variable wurde lediglich für die DVA-Modelle verwendet. Im Original von Andersen und Sauer (2007) wird zur Berechnung des Sehwinkels eine vereinfachte Gleichung verwendet, bei der die Breite des Vorderfahrzeugs durch den Abstand zum Folgefahrzeug geteilt wird. In dieser Arbeit wurde der Genauigkeit halber die exakte Formel verwendet:

$$\alpha = 2 \cdot \operatorname{atan}\left(\frac{\text{Breite}_{VF}}{2 \cdot \text{Distanz}}\right) \cdot \frac{\pi}{180} \quad (8)$$

4.7.2 Statistische Analysen

Zur Beantwortung der ersten Fragestellung, ob der Streckentyp einen jeweils unterschiedlichen Effekt auf die Vorhersagegüte der Modelle ausübt, werden für alle vier Kombinationen aus Variable (Distanz, Geschwindigkeit) und Abweichungsmaß (RMSD, r) jeweils separate Analysen vorgenommen. Gerechnet wird eine zweifaktorielle 3×4 ANOVA, mit dem Faktor Modell (messwiederholt; vierstufig mit Helly, DVA, DVA-PT, Gipps) und dem Faktor Streckentyp (messwiederholt; dreistufig mit Autobahn, Landstraße, Stadt).

Je nach Art der Wechselwirkung, kann Fragestellung 2 (Unterschied der Streckentypen) mit dem Haupteffekt des Streckentyps der vorangegangenen 3×4 ANOVA beantwortet werden. Dann werden weiterhin post hoc Kontraste gerechnet, um zu testen welche Streckentypen sich konkret unterscheiden.

Die dritte und zentrale Fragestellung dieser Arbeit – schneiden die psychologisch plausibleren Modelle (DVA und DVA-PT) besser ab, als die psychologisch unplausiblen Modelle (Helly und Gipps) – wird mithilfe eines Kontrasttests beantwortet.

Für den Fall, dass die Analyse für Fragestellung 1 einen Interaktionseffekt feststellt, der keine globale Interpretationen der Haupteffekte für die Faktoren Modell und Streckentyp zulässt, erfolgt eine deskriptive Analyse der Daten.

5 Ergebnisse

Insgesamt wurden 486 Minuten und 45 Sekunden Datenmaterial gesammelt, wovon 46 Minuten und 20 Sekunden ausgeschlossen und nicht interpoliert wurden. Die Ausfallquote beträgt somit insgesamt 9%. Zwischen den Individuen schwankt die Ausfallquote zwischen 5% und 13%. Zunächst werden die wichtigsten deskriptiven Kennwerte der empirischen Daten vorgestellt. Anschließend werden in Form von zwei Beispielen Verlaufsdiagramme gezeigt, um einen visuellen Eindruck der Modellvorhersagen für die empirischen Fahrdaten zu vermitteln. Es folgen die Ergebnisse der statistischen Analysen zur Beantwortung der Fragestellungen.

5.1 Deskriptive Auswertung der empirischen Daten

Autobahnfahrten machten 39% der gesamten Fahrt aus, die Landstraßenfahrten 24% und die Stadtfahrten 37%. Im Mittel liegen pro Proband valide Fahrdaten über 40 Minuten vor. Die von den Probanden mittlere gehaltene Distanz und die mittlere gefahrene Geschwindigkeit sind getrennt für jeden Streckentyp in Tabelle 4 dargestellt.

Tabelle 4

Mittelwerte (M) und Standardabweichungen (SD) der empirisch gemessenen Distanz und Geschwindigkeit

	Distanz (m)		Geschwindigkeit (m/s)	
	M	SD	M	SD
Autobahn	31,84	6,67	25,39	1,94
Landstraße	31,88	7,09	21,07	0,59
Stadt	15,64	3,02	9,79	0,42

5.2 Verlaufsdiagramme

Im Folgenden seien einige Ausschnitte der Modellvorhersagen exemplarisch dargestellt. Abbildung 4 zeigt einen Ausschnitt des Geschwindigkeitsverlaufs von Proband sechs während der Autobahnfahrt. Zudem werden die Geschwindigkeitsverläufe des Vorderfahrzeugs und der Modellvorhersagen abgebildet. Besonders am Anfang zeigen die Vorhersagen des Gipps-Modells und DVA-PT noch starke Schwankungen, die sich in anderen hier nicht dargestellten Ausschnitten auch bei den anderen Modellen zeigen. Es fällt auf, dass die Modelle sehr ähnliche Vorhersagen machen und dabei vor allem das Fahrprofil des Vorderfahrzeugs synchronisieren.




Abbildung 4. Geschwindigkeitsverlauf von Proband sechs und dem Vorderfahrzeug (VF), sowie die dazugehörigen Modellvorhersagen für die ersten 150 Sekunden der Autobahnfahrt.

Ein Beispiel für die gehaltene Distanz zum Vorderfahrzeug ist in Abbildung 5 zu sehen. Wie bei den Vorhersagen für die Geschwindigkeit liegen zwischen den Modellvorhersagen geringere Unterschiede vor, als zwischen Vorhersagen und empirischen Daten. In diesem

Beispiel ist zu sehen, dass die Modelle einen wesentlich konstanteren Abstand zum Vorderfahrzeug halten als der Proband.




Abbildung 5. Gehaltener Abstand zum Vorderfahrzeug von Proband sechs und die dazugehörigen Modellvorhersagen für die ersten 200 Sekunden der Autobahnfahrt.

5.3 Analyse des Interaktionseffekts zwischen Modell und Streckentyp (Fragestellung 1)

Es wurde eine zweifaktorielle 3×4 ANOVA mit Messwiederholung zur Testung eines Interaktionseffekts zwischen dem Faktor Modell und Streckentyp gerechnet. Diese Analyse erfordert zunächst die Prüfung zweier Voraussetzungen: 1. Die Voraussetzung einer normalverteilten abhängigen Variablen und 2. das Vorliegen von Sphärizität. Mithilfe des Shapiro-Wilk Tests wurden die Verteilungen pro Zelle auf Normalverteilung überprüft. In acht von 48 Fällen, wies der Test signifikante Abweichungen von einer Normalverteilung auf. Da diese Fälle nur einen kleinen Anteil bilden, und die ANOVA robust gegen eine Verletzung dieser Voraussetzung ist (Schmider, Ziegler, Danay, Beyer, & Bühner, 2010) – insbesondere wenn alle Zellen gleich besetzt sind, was hier der Fall ist – soll hier auf die Anwendung eines

parametrischen Tests zugunsten einer größeren Power nicht verzichtet werden. Auch die zweite Voraussetzung der Sphärizität ist laut den Ergebnissen des Mauchly's Tests in einigen Fällen verletzt. In diesen Fällen werden korrigierte Ergebnisse betrachtet, die nach dem Korrekturverfahren von Greenhouse-Geisser angepasst wurden. Falls eine Korrektur stattgefunden hat, wird dies im Folgenden genannt. Der maximal tolerierte Alpha-Fehler liegt für alle Analysen bei ,05. Ist der p-Wert kleiner als ,05 wird die Null-Hypothese verworfen. Zur Bestimmung der Power des verwendeten Tests wurde die Software G*Power Version 3.1 verwendet (Faul, Erdfelder, Lang, & Buchner, 2007).

Der Interaktionseffekt zwischen den beiden Faktoren Modell und Streckentyp auf die Vorhersagegüte für die Distanz ist signifikant, $F(2,44; 26,79) = 4,90$; $p = ,011$; $\eta_p^2 = 0,31$; $1-\beta > ,99$ (korrigiert). Auch unter Verwendung des Gütemaßes r interagieren die Faktoren Modell und Streckentyp in der Vorhersagegüte für die Distanz, $F(6; 66) = 10,15$; $p < ,001$; $\eta_p^2 = 0,48$; $1-\beta > ,99$. Der Interaktionseffekt zwischen beiden Faktoren auf die Vorhersagegüte der Geschwindigkeit ist hingegen nicht signifikant. Das gilt für die Analysen mit RMSD ($F(2,53; 27,84) = 4,43$; $p = ,140$; $\eta_p^2 = 0,16$; $1-\beta > ,99$; korrigiert) und mit r ($F(2,68; 29,53) = 1,72$; $p = ,188$; $\eta_p^2 = 0,14$; $1-\beta = ,99$; korrigiert). Die Power der durchgeführten Tests war jeweils sehr hoch. So kann eine zu geringe Power als Grund für die nicht signifikanten Ergebnisse der Geschwindigkeitsvorhersagen nicht in Frage kommen.

Die Gütekennwerte der vier Modelle pro Streckentyp sind in Abbildung 6 aufgeführt, jeweils für Distanz (obere Reihe) und Geschwindigkeit (untere Reihe) und getrennt für die Abweichungsmaße RMSD (linke Spalte) und r (rechte Spalte). Für das Maß RMSD gilt: Je niedriger der Wert, desto besser die Vorhersagegüte. Bei r verhält es sich genau umgekehrt. Die dazugehörigen Parameterwerte der Modelle, mit denen die finalen Vorhersagen generiert wurden, sind in Anhang A aufgelistet. Ebenfalls sind die exakten Gütekennwerte in Tabellenform in Anhang B aufgeführt.




Abbildung 6. Modellgüte für alle Modelle getrennt für die Streckentypen pro Variable (Distanz und Geschwindigkeit) und Gütemaß (RMSD und r).

Anhand der Abbildung ist zu sehen, dass die beiden Gütemaße einen jeweils ähnlichen Trend aufweisen, sowohl für die Modelle als auch die Streckentypen. Vielmehr unterschieden sich die Daten zwischen den vorhergesagten Variablen, Distanz und Geschwindigkeit. Die Abbildung verdeutlicht an dieser Stelle die zuvor beschriebenen Ergebnisse der signifikanten Interaktionseffekte für die Vorhersagen der Distanz auf der einen Seite und die nicht vorhandene Interaktion für die Geschwindigkeitsvorhersagen auf der anderen Seite. Anhand des Korrelationskoeffizienten ist auch zu erkennen, dass die Vorhersagen für die Distanz insgesamt schlechter sind als für die Geschwindigkeit und die Modellgüte zwischen den Individuen stärker variiert. Im Folgenden werden die Effekte der einzelnen Faktoren näher betrachtet.

5.4 Analyse der Unterschiede zwischen Streckentypen (Fragestellung 2)

Für die Vorhersage der Distanz zeigt sich für beide Gütemaße ein Interaktionseffekt. Zwar sind die Vorhersagen für die Landstraßenfahrt bei allen Modellen und für beide Gütemaße am schlechtesten (vgl. Abbildung 6), allerdings sagen die Modelle von Gipps und Helly die Stadtfahrt am besten vorher, während die DVA-Modelle die Autobahnfahrt am besten vorhersagen. Somit ist der Effekt des Streckentyps in Hinblick auf die Modelle nicht einheitlich und der Haupteffekt aus der 3×4 ANOVA kann global nicht interpretiert werden. Auf Grundlage einer deskriptiven Betrachtung der Gütekennwerte in Hinblick auf den Einfluss der Streckentypen, sind die Vorhersagen der Modelle von Gipps und Helly für die Stadtfahrt hervorzuheben: Die absoluten Vorhersagen (RMSD) und der Zusammenhang der Vorhersagen mit den empirischen Daten (r) sind hier deutlich besser als die der anderen Streckenabschnitte und Modelle. Die mittlere absolute Abweichung (RMSD) der Vorhersagen des Gipps-Modells liegt hier nur bei 4,16 m ($SD = 0,97$) und des Helly-Modells sogar nur bei 3,95 m ($SD = 0,85$). Zum Vergleich: der Gesamtmittelwert aller Modelle und Streckentypen liegt bei 6,50 m.

Bei der Geschwindigkeit liegen keine Interaktionen des Streckentyps mit dem Modell vor, somit können Haupteffekte global interpretiert werden. Ein Haupteffekt für den Streckentyp zeigt sich allerdings nur mit dem Maß RMSD ($F(1,33; 14,58) = 14,95; p = ,001; \eta_p^2 = 0,58; 1-\beta > ,99$; korrigiert). Mit dem Korrelationskoeffizienten zeigt der Test keinen signifikanten Effekt ($F(2; 22) = 2,60; p = ,10; \eta_p^2 = 0,19; 1-\beta = ,70$). Da die Power nicht den empfohlenen Mindestwert von ,8 erreicht (Cohen, 1988), ist unklar, ob mit dem Korrelationskoeffizienten trotzdem ein Effekt vorliegt, der in diesem Test nur nicht gefunden werden konnte.

Mit RMSD sind die Vorhersagen für die Autobahnfahrt am besten ($M = 0,85, SD = 0,32$), gefolgt von den Vorhersagen für die Landstraßenfahrt ($M = 1,14, SD = 0,55$). Am schlechtesten sind die Vorhersagen für die Stadtfahrt ($M = 1,49, SD = 0,74$). Auch die individuelle Varianz innerhalb jedes Streckentyps unterscheidet sich. Die Varianz für die Vorhersagen der Autobahnfahrt sind am geringsten – für die der Stadtfahrt am höchsten. Post hoc gerechnete Kontraste (zweiseitig getestet mit jeweils ungleichen Varianzen zwischen den Gruppen) zeigen, dass sich die Vorhersagen für den Autobahnabschnitt signifikant von denen für den Landstraßenabschnitt ($t(76,23) = 3,15; p = ,002; r = 0,34; 1-\beta = 0,48$) und den Stadtabschnitt ($t(64,25) = 5,49; p < ,001; r = 0,56; 1-\beta = 0,88$) unterscheiden. Vorhersagen für die Landstraße und Stadt unterscheiden sich ebenfalls signifikant ($t(86,51) = 2,65; p = ,01; r = 0,28; 1-\beta = 0,38$).

Die Effektstärken weisen nach Cohens Empfehlungen für die Einstufung der Größe von Effekten (1992) auf mittlere (ab $r = ,3$) bis große Effekte (ab $r = ,5$) hin.

5.5 Analyse der Modellunterschiede (Fragestellung 3)

Auch die Haupteffekte des Faktors Modell auf die Vorhersagen der Distanz können nicht interpretiert werden. Die Effekte der Modelle sind über die Streckentypen hinweg nicht einheitlich. Zum Beispiel sind mit RMSD die Vorhersagen des DVA-Modells für den Autobahnabschnitt besser als die von DVA-PT, für die anderen beiden Streckentypen ist es jedoch umgekehrt. Auch mit dem Korrelationskoeffizienten zeigen sich je nach Streckentyp uneinheitliche Effekte für die Modelle: Für die Autofahrt zeigt das Gipps-Modell die schwächste Modellgüte, während es bei der Stadtfahrt die Zweitbeste aufweist. Da der Interaktionseffekt demnach nicht durchgängig ordinal ist, soll aus diesem Grund auf eine Interpretation des Haupteffekts der Modelle für die Vorhersagen der Distanz verzichtet werden. In Hinblick auf einen Vergleich zwischen psychologisch plausiblen Modellen (DVA und DVA-PT) mit psychologisch unplausiblen (Helly und Gipps), ist die Rechnung eines geplanten Vergleich mit dem Gütemaß RMSD jedoch möglich, da die Modelle Helly und Gipps für jeden der drei Streckentypen niedrigere Abweichungen aufweisen als die DVA-Modelle – in dem Fall liegt also keine disordinale Interaktion vor. Der geplante Vergleich resultiert in einem signifikanten Unterschied der beiden Modellgruppen mit $t(117,54) = 7,2$; $p < ,001$; $r = 0,55$; $1-\beta = ,98$, einseitig getestet und bei ungleichen Varianzen. Nach Cohen (1992) kann dies als großer Effekt eingestuft werden.

Für die Geschwindigkeit können die Modellunterschiede ungeachtet der Streckentypen analysiert werden, da hier mit beiden Gütemaßen keine Interaktion vorliegt. Die Ergebnisse der 4×3 ANOVA für die Geschwindigkeit zeigen, dass mit RMSD und r ein Haupteffekt des Modells vorliegt (RMSD: $F(2,05; 22,57) = 37,44$; $p < ,001$; $\eta_p^2 = 0,77$; $1-\beta > ,99$; korrigiert; r : $F(1,65; 18,20) = 27,96$; $p < ,001$; $\eta_p^2 = 0,72$; $1-\beta > ,99$; korrigiert). Der geplante Vergleich zwischen den beiden Gruppen Helly und Gipps gegenüber den DVA-Modellen zeigt einen hochsignifikanten Unterschied mit $t(86,36) = 7,37$; $p < ,001$; $r = 0,62$; $1-\beta = ,96$, für RMSD und $t(72,33) = 7,03$; $p < ,001$; $r = 0,64$; $1-\beta = ,92$, für den Korrelationskoeffizienten, jeweils einseitig getestet und bei ungleichen Varianzen. Hier sind die Effekte sogar noch größer als es für die Vorhersagen der Distanz mit dem Gütemaß RMSD der Fall war.

Anhand der deskriptiven Daten ist auch hier zu sehen, dass es sich genau entgegengesetzt der Erwartung verhält und die DVA-Modelle schlechter abschneiden als die Modelle Gipps und Helly – das gilt für das Gütemaß RMSD und den Korrelationskoeffizienten. Wie schon bei den Streckentypen, liegen auch zwischen den Modellen Unterschiede in der interindividuellen Varianz vor. Sie ist bei den DVA-Modellen größer als bei den anderen beiden (vgl. Abbildung 6).

6 Diskussion

6.1 Beantwortung der Fragestellungen

In der vorliegenden Arbeit wurden vier Fahrermodelle für die Folgefahrt verglichen. Neben den zwei etablierten Modellen von Gipps und Helly wurde das DVA-Modell (Andersen & Sauer, 2007) in den Vergleich mit aufgenommen. Es beansprucht psychologisch plausibler zu sein als die anderen beiden Modelle und damit menschliches Fahrverhalten besser vorhersagen zu können, indem es den Sehwinkel als Eingangssignal verwendet, anstatt der Geschwindigkeit und der Distanz. Eine Weiterentwicklung des DVA-Modells um die Komponente einer Wahrnehmungsschwelle wurde vorgenommen, um sich mit dem Modell den menschlichen Wahrnehmungsfähigkeiten weiter anzunähern. Die Ergebnisse dieser Arbeit zeigen, dass die DVA-Modelle entgegen der Annahme schlechtere Vorhersagen zeigten (Fragestellung 3). Die Güte der beiden Modellgruppen untereinander ähnelt sich dabei sehr stark. Für die Vorhersagen der Geschwindigkeit war dieser Effekt statistisch bedeutsam. Für die Vorhersagen der Distanz, konnte der direkte Vergleich der beiden Modellgruppen nur mit dem Gütemaß RMSD durchgeführt werden. Hier entspricht das Ergebnis denen für die Vorhersage der Geschwindigkeit. Wird der Korrelationskoeffizient verwendet, müssen die Modelle unter Berücksichtigung des Streckentyps betrachtet werden, da sich der Modellvergleich je nach Streckentyp anders darstellt.

Auf Grundlage vorheriger Studien war ein Einfluss der Fahrsituation auf das menschliche Fahrverhalten und somit auch der Vorhersagegüte der Modelle anzunehmen (Ossen & Hoogendoorn, 2011; Ranjitkar et al., 2005). Aus diesem Grund wurde die Fahrsituation im Versuchsdesign berücksichtigt und in Form drei verschiedener Streckentypen (Autobahn, Landstraße, Stadt) realisiert, um zu testen welchen Effekt unterschiedliche Streckentypen auf die Vorhersagegüte der Modelle nehmen. Zunächst musste jedoch geprüft werden, ob der Einfluss des Streckentyps auf die Modelle einheitlich ist, oder die Modelle jeweils von unterschiedlichen

Streckentypen profitieren (Fragestellung 1). Tatsächlich zeigte sich ein signifikanter Interaktionseffekt zwischen den Modellen und der Streckentypen auf die Vorhersagegüte für die Distanz. Für die Vorhersage der Geschwindigkeit gilt das nicht. Hier zeigt sich kein signifikanter Interaktionseffekt. Die Unterschiede zwischen den Streckentypen sind bei der Geschwindigkeit demnach bei allen Modellen gleich. Es werden für die Stadtfahrt die schlechtesten Vorhersagen generiert. Das gilt auch für die Modelle von Gipps und Helly. Am besten sind die Modellvorhersagen für die Autobahnfahrt, gefolgt von den Vorhersagen für die Landstraßenfahrt. Fragestellung zwei kann demnach mit ja beantwortet werden: Die Modellvorhersagen unterscheiden sich zwischen den drei Streckentypen. Bei der Distanz ist dieser Effekt in Bezug auf die Modelle allerdings uneinheitlich.

Neben der Fahrsituation war weiterhin anzunehmen, dass auch die Wahl der vorhergesagten Variable, Distanz oder Geschwindigkeit, zu unterschiedlichen Ergebnissen eines Modellvergleichs führt. Die Auswertung wurde deshalb getrennt für die Variablen vorgenommen. Wie die bisherigen Beantwortungen der Fragestellungen bereits zeigen, war auch in dieser Studie ein Unterschied zwischen den Variablen zu sehen. Das betraf nicht nur die Tatsache der schlechteren Vorhersagen für die Distanzen, wie mithilfe des Korrelationskoeffizienten zu sehen ist, sondern auch die Interaktionseffekte zwischen Modellen und Streckentypen, wie die Beantwortung von Fragestellung 1 zeigt.

In vorherigen Studien, wurden verschiedene Maße zur Beurteilung der Güte verwendet. So wurde auch in diesem Punkt die Auswertung getrennt für die zwei Gütemaße RMSD und r vorgenommen, da sie jeweils zwei andere Aspekte der Modellgüte quantifizieren: Die absolute Abweichung der Vorhersagen (RMSD) und ihren Zusammenhang mit den empirischen Daten (r). Die Frage nach dem Mehrwert einer Auswertung mit zwei Maßen kann nicht eindeutig beantwortet werden. Der allgemeine Trend ist für beide Maße jeweils der gleiche. Bei einer detaillierten Betrachtung eröffnen sich allerdings Differenzen. Zum Beispiel bringen die Maße bei den Distanzvorhersagen für die Autobahn- und Landstraßenfahrt unterschiedliche Modellrangfolgen hervor, auch wenn anzunehmen ist, dass diese Modellunterschiede jeweils nicht statistisch bedeutsam sind.

6.2 Schlussfolgerungen

6.2.1 Modellvergleich

Es kann festgehalten werden, dass in dieser Arbeit die DVA-Modelle in ihrer Vorhersagegüte schwächer abschneiden als die Modelle von Gipps und Helly. Die Ergebnisse widersprechen damit den Ergebnissen von Andersen und Sauer (2007), die beim Vergleich des DVA-Modells mit dem Gipps-Modell einen (wenn auch nur leichten) Vorteil für das DVA-Modell feststellten. Allerdings muss angemerkt werden, dass sie ihre Daten während einer Autobahnfahrt sammelten und den Modellvergleich mit Hilfe des Korrelationskoeffizienten vornahmen. Betrachtet man die hier gewonnenen Ergebnisse für die Autobahnfahrt mit r , zeigt sich ein ähnliches Bild wie bei Andersen und Sauer (2007). Dieses Beispiel zeigt erneut, wie wichtig es ist die Fahrsituation zu berücksichtigen – und in diesem Fall auch das Gütemaß.

Die Modelle DVA, DVA-PT und Helly unterscheiden sich in ihrer Konzeption nur geringfügig – nur das Gipps-Modell grenzt sich von den anderen drei Modellen ab. Trotzdem zeigen die Ergebnisse der Vorhersagegüte der Modelle, dass sich vielmehr die Modelle Helly und Gipps ähneln und sich von den DVA-Modellen abgrenzen. Dieses Ergebnis lässt einige Schlussfolgerungen über Ursachen für die Unterschiede der Modellgüte zu: Da sich das DVA-Modell lediglich in der Verwendung des Schwinkels vom Helly-Modell unterscheidet, deuten die Ergebnisse darauf hin, dass dies der Grund für die schlechteren Vorhersagen ist. Mit dem Schwinkel wird eine niedrigere Gewichtung von Distanzveränderungen bei großen Distanzen erreicht. Die Autoren nahmen an, damit den menschlichen Wahrnehmungseigenschaften zu entsprechen. Diese Maßnahme zeigt allerdings keine positive Wirkung. Das muss noch nicht bedeuten, dass die Annahme der Autoren falsch ist. Es ist jedoch möglich, dass die motorischen Reaktionen keine direkte Umsetzung der wahrgenommen Veränderungen darstellen und letztlich sagen die Modelle die Reaktionen des Fahrers vorher und nicht seine Wahrnehmung. So kann es beispielsweise der Fall sein, dass bei geringen Distanzen kleine Distanzveränderungen wahrgenommen werden, darauf jedoch keine regelnde Reaktion erfolgt, während bei großen Distanzen sofort eine Geschwindigkeitsanpassung vorgenommen wird, sobald eine Distanzveränderung wahrgenommen wird.

So wie der Schwinkel als potentieller Verursacher für die schlechtere Güte der DVA-Modelle angenommen werden kann, können andere Ursachen mit den Ergebnissen dieser Arbeit ausgeschlossen werden. Ossen (2008) vermutete, dass die vom Modell direkt vorhergesagten

Variablen, die in der Modellgleichung spezifiziert sind, der Grund dafür sind, dass manche Modelle bei der Vorhersage der Distanz profitieren, während andere bessere Vorhersagen für die Geschwindigkeit machen. In der Modellgleichung des Gipps-Modells wird die Geschwindigkeit vorhergesagt – in den Gleichungen der anderen Modelle die Beschleunigung. Die Ähnlichkeiten der Vorhersagegüte zwischen dem Helly- und Gipps-Modell in dieser Stichprobe, sowohl für Distanz als auch für Geschwindigkeit, widersprechend der Annahme von Ossen (2008). Dieser Aspekt kommt als Ursache für Unterschiede in der Modellgüte hier somit nicht in Frage.

Die stichprobenartige Betrachtung der Verlaufsdiagramme für die Geschwindigkeit offenbarte, dass alle vier Modelle dem Profil des Vorderfahrzeugs stärker entsprechen, als dem Profil des Folgefahrzeugs. Trotz Maßnahmen, wie der Verwendung des Seh winkels und einer Wahrnehmungsschwelle, synchronisieren die Modelle primär das Profil des Vorderfahrzeugs. Olstam und Tapani (2004) kritisieren diese Synchronisation des Vorderfahrzeugs zunächst nur am Gipps-Modell. Auf Grundlage erster explorativer Analysen mit der hier betrachteten Stichprobe, lässt sich diese Kritik auf alle Modelle ausdehnen. In zukünftigen Studien könnte zusätzlich ein Fehlermaß für die Abweichung der Modellvorhersagen von den Fahrdaten des Vorderfahrzeugs eingeführt werden, um zu quantifizieren, wie stark sich die Modelle vom Profil des Vorderfahrzeugs abheben.

Die Verlaufsdiagramme unterstreichen den Eindruck, dass die Anpassungen der Eingangssignale an die menschlichen Wahrnehmungsfähigkeiten durch einzelne Maßnahmen nicht auszureichen scheinen, um Modellvorhersagen zu verbessern. Boer (1999) vertritt die Meinung, dass Modelle, die vorgeben psychologisch plausibel zu sein, wesentlich komplexer sein müssen. Denkbar wäre seiner Meinung nach, dass das menschliche Fahrverhalten in verschiedenen Situationen auch verschiedenen Gesetzmäßigkeiten folgt. In einigen Situationen könne das Fahrverhalten tatsächlich dem eines Reglers ähneln – in anderen sei Regeln wohlmöglich ein untergeordnetes Ziel.

6.2.2 Streckentypen

Bei den Vorhersagen für die Distanz machen die Interaktionseffekte der Streckentypen mit den Modellen deutlich, dass die Wahl des Streckentyps darüber entscheiden kann, wie das Ergebnis eines Modellvergleichs aussieht oder aber auch, ob sich Modellunterschiede gegenüber

individueller Varianz durchsetzen können, wie es in vorherigen Studien auftrat (Brockfeld et al., 2004; Ossen & Hoogendorn, 2011).

Auf der anderen Seite zeigte sich bei der Geschwindigkeit einheitlich, dass die Vorhersagen für die Stadtfahrt schlechter sind als für die Vorhersagen der Autobahn- und Landstraßenfahrt. Ein Grund für dieses Ergebnis, kann die stärkere Schwingung des Geschwindigkeitsprofils des Vorderfahrzeugs sein, die während der Autobahnfahrt vermutlich geringer ist, als bei Fahrten durch die Stadt. Diese Eigenschaft des Geschwindigkeitsprofils wurde in bisherigen Studien noch nicht gezielt variiert. Dass Folgefahrtmodelle starke Schwingungen schlechter vorhersagen können, wurde allerdings auch als Erklärung für die schlechteren Vorhersagen von Beschleunigungen angeführt (Ossen, 2008; Ranjitkar et al., 2005).

6.2.3 Variable der Vorhersage

Die Erkenntnis dieser Studie, dass die Vorhersagen für die Distanz schlechter sind als die für die Geschwindigkeit, entspricht den Ergebnissen von Ranjitkar et al. (2004). Ihre Begründung für die schlechteren Vorhersagen ist ein sich aufsummierender Fehler, der dadurch entstanden sein könne, dass die Distanz in ihrer Studie aus den Positionsdaten der beiden Fahrzeugen errechnet wurde, während die Geschwindigkeit direkt aufgezeichnet werden konnte. In dieser Studie konnte die Distanz mithilfe des Radars direkt gemessen werden. Dennoch blieb der Unterschied zwischen den Distanz- und Geschwindigkeitsvorhersagen bestehen. Darüber hinaus hätte diese Erklärung auch nicht ausgereicht, um die Unterschiede in den Rangfolgen der Modelle vorherzusagen, die auch Ranjitkar et al. (2004) fanden. In dieser Studie zeigt sich je nach Variable ein gänzlich unterschiedliches Bild. Das gilt für die Rangfolge der Modelle, die Unterschiede zwischen den Streckentypen (diese besonders) und sogar ihrer Interaktionseffekte. Dabei sind die Variablen nicht unabhängig voneinander: Kann zum Beispiel das Geschwindigkeitsprofil nicht adäquat wiedergegeben werden, also die Veränderung der Distanz, leidet auch die Vorhersagegüte der Distanz selbst. Der Fehler, bei der Geschwindigkeitsvorhersage spielt also bei der Distanzvorhersage eine Rolle. Es ist jedoch nicht die einzige Fehlerquelle, denn für die Vorhersage der Distanz muss schließlich auch der absolute Abstand vorhergesagt werden können. In diesem Punkt ist die Vorhersagegüte der Distanz unabhängig von der Vorhersagegüte der Geschwindigkeit. Das Ergebnis der deutlich besseren Geschwindigkeitsvorhersagen deutet an, dass sie somit nicht als Hauptfehlerquelle für die

Distanzvorhersagen in Frage kommen. Das erklärt warum die Effekte für die Modelle, Streckentypen und ihre Interaktionen sich zwischen den Variablen so verschieden darstellen können.

Zusammengefasst heißt es, dass es den Modellen besser gelingt die Veränderung der Distanz vorherzusagen (also die Geschwindigkeit), als das absolute Niveau der gehaltenen Distanz. Eine Erklärung für dieses Ergebnis könnte sein, dass die Wahl der Distanz mehr Einflussfaktoren bzw. mehr Freiheitsgraden unterliegt, als die Wahl der Geschwindigkeit. Wie an den empirischen Daten zu sehen ist, gibt es unter den Probanden mehr Variabilität in der Wahl der Distanz. Diese Erkenntnis ist bis zu einem gewissen Maße trivial. Schließlich lautet die Aufgabenstellung, dem vorausfahrenden Fahrzeug zu folgen und das beinhaltet das Nachahmen der Aktionen des Vorderfahrzeugs. Die Distanz hingegen kann nahezu beliebig gewählt werden. Voraussetzung ist lediglich, dass das Vorderfahrzeug in Sichtweite ist, sodass dessen Aktionen überhaupt wahrgenommen werden können. Somit ist es wahrscheinlich, dass wesentlich mehr Faktoren auf die Wahl der Distanz Einfluss nehmen, als nur eine subjektive Wunschdistanz, wie es die Modelle vorschlagen. Laut Abbildung 5 sagen die Modelle ein entsprechend konstantes Abstandsverhalten vorher, während der echte Fahrer variabler agiert.

Die getrennte Auswertung für die Variablen stellt sich vor dem Hintergrund der Ergebnisse schließlich als gerechtfertigt heraus. Das Vorgehen von Ossen (2008), eine kombinierte Variable aus Distanz und Geschwindigkeit zu verwenden, ist ausgehend von den hier gewonnenen Ergebnissen deshalb nicht zu empfehlen.

6.2.4 Gütemaße

Ossen (2008) gelangte zu dem Fazit, dass bei einem Modellvergleich verschiedene Gütemaße die gleichen Ergebnisse hervorbringen. Sie verglich die Maße Theils' u und RMSD. Das Fazit des Vergleichs von RMSD mit dem Korrelationskoeffizienten in dieser Studie ist jedoch ambivalent, da der allgemeine Trend der Effekte durch die Modelle und Streckentypen zwar gleich ist, sich die Interpretationen zwischen den Gütemaßen im Detail aber unterscheiden. Wünschenswert für zukünftige Forschung wäre ein systematischer Vergleich aller Gütemaße an verschiedenen Stichproben, so wie es Ossen (2008) mit RMSD und Theils' u an Stichproben mit unterschiedlich hohem Messfehler vornahm. Dabei verspräche ein Blick auf den Einfluss der Gütemaße auf die Schätzungen der freien Parameter weitere Erkenntnisse.

6.2.5 Individuelle Unterschiede

Zuletzt spielten in vorherigen Studien auch individuelle Unterschiede eine große Rolle und waren teilweise größer als die Unterschiede zwischen den Modellen (Brockfeld et al., 2004; Ossen & Hoogendoorn, 2011). Hier konnten hingegen statistisch bedeutsame Unterschiede zwischen der Vorhersagegüte der Modelle gefunden werden. Gleichzeitig wurde aber auch sichtbar, dass dies nicht in allen Bedingungen gelingt. Besonders für die Vorhersagen der Distanz bei den Autobahnfahrten, heben sich die Modelle weniger voneinander ab, als z.B. bei der Stadtfahrt.

6.3 Reflexion der Stärken und Grenzen dieser Arbeit

Die Tatsache, dass in dieser Stichprobe – trotz der zuvor erwähnten hohen individuellen Varianz – statistisch bedeutsame Modellunterschiede gewonnen werden konnten, spricht für eine Stichprobe mit großen Datenmengen pro Individuum, so wie sie hier gewählt wurde. Die Messung von Fahrdaten eines Individuums über einen längeren Zeitraum ist jedoch sehr aufwendig, vor allem wenn sie zugunsten einer hohen ökologischen Validität im realen Kontext erhoben werden. Der Preis ist dann meist eine geringe Anzahl an Individuen. In bisherigen Realfahrtstudien lag sie zwischen $n=1$ (Panwai & Dia, 2005) bis $n=10$ (Ranjitkar et al., 2005). Mit zwölf Probanden war diese Stichprobe gerade groß genug, um inferenzstatistische Analysen mit einer angemessenen Power durchführen zu können, was in vorherigen Studien noch nicht unternommen wurde. Um in Zukunft jedoch auch kleine Effekte identifizieren zu können oder z.B. Zusammenhänge mit personenbezogenen Variablen, wie Fahrerfahrung oder Alter, wäre eine größere Stichprobe angemessen.

Ein weiteres Feld für zukünftige Forschung ist die genauere Analyse von Mustern in den Fahrdaten, sowohl in den empirischen Daten als auch in ihrer Passung mit den Modellvorhersagen. Relevante Fragen sind z.B.: In welchen Passagen der Fahrt machen die Modelle besonders genaue oder ungenaue Vorhersagen und was sind Eigenschaften dieser Passagen, die dafür verantwortlich sein könnten? Die getrennte Betrachtung verschiedener Streckentypen, war ein erster explorativer Ansatz in diese Richtung. Da sich hier herausstellte, dass unterschiedliche Streckentypen die Modellvorhersagen beeinflussen, sollte in zukünftigen Arbeiten systematisch geprüft werden, welche Eigenschaften der Streckentypen es sind (wie z.B. die Schwingungen im Geschwindigkeitsprofil), die für diese Unterschiede verantwortlich sind.

Eventuell finden sich dann weitere Anhaltspunkte, die Aufschluss darüber geben unter welchen Umständen eine psychologisch plausible Komponente zum Vor- oder Nachteil für die Vorhersagegüte eines Modells wird und damit – und das ist das eigentliche Ziel – wann der menschliche Fahrer sie nutzt. Die Betrachtung dessen, wie und nicht nur ob solche psychologischen Komponenten, wie der Schwinkel oder Wahrnehmungsschwellen, für die Kognition des Menschen eine Rolle spielen, ist schließlich die große Chance, welche die quantitative Modellierung für die Psychologie bereithält.

Ein Thema, dass in dieser Arbeit nicht weiter aufgegriffen wurde, sind die Schätzwerte für die freien Parameter und die Kalibrierungsmethoden diese zu finden. Die Interpretation der Güte der Modelle setzt voraus, dass die besten Parameter für die jeweiligen Modelle gefunden wurden. Ein Problem wäre es, wenn für ein Modell seine besten Parameter verwendet wurden, während das für ein anderes Modell nicht zutrifft. Ob das ein reales Problem ist und wie groß dieses Problem wäre (was das also für die Vorhersagegüte der Modelle bedeutet) ist jedoch unklar. Diese Fragestellungen sind vor allem mathematischer Natur. Ihre Beantwortung ist jedoch grundlegend, wenn die quantitative Modellierung in der Psychologie Anwendung finden soll.

6.4 Fazit

Abschließend kann festgehalten werden, dass die Integration einzelner aus der Psychologie gewonnener Erkenntnisse, in dieser Stichprobe keine Verbesserung für die Vorhersagen von menschliche Folgefahrverhalten zeigte. Die Antwort auf die Frage nach einem quantitativen kognitiven Folgefahrmodell gestaltet sich vermutlich komplexer (Boer, 1999).

Die Erkenntnisse über das Modellverhalten in verschiedenen Fahrsituationen, für die verschiedenen Vorhersagevariablen und Gütemaße, können in Zukunft genutzt werden, wenn diese Modelle in Simulationen von z.B. Verkehrsflüssen zum Einsatz kommen. Vor allem sind sie aber von hohem Nutzen für das methodische Vorgehen weiterer Modellvergleiche, genauso wie sie zur Einordnung der oft widersprüchlichen Ergebnisse bisheriger Vergleichsstudien dienen.

Literaturverzeichnis

- Andersen, G. J., & Sauer, C. W. (2007). Optical Information for Car Following: The Driving by Visual Angle (DVA) Model. *Human factors*, 49(5), 878–896. doi: 10.1518/001872007X230235
- Baron, S., Elkind, J.I., Kleinman, D.L., Duncan, C., & Levison, W.H. (1969). *Application of Optimal Control Theory to the Prediction of Human Performance in a Complex Task*, Final Report, Bolt Beranek and Newman INC., AFFDL-TR-69-81.
- Bekey, G. A., Burnham, G. O., & Seo, J. (1977). Control theoretic models of human drivers in car following. *Human Factors*, 19(4), 399-413.
- Boer, E. R. (1999). Car following from the driver's perspective. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2(4), 201–206. doi: 10.1016/S1369-8478(00)00007-3.
- Brackstone, M., & McDonald, M. (1999). Car-following: a historical review. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2(4), 181-196. doi: 10.1016/S1369-8478(00)00005-X
- Brockfeld, E., Wagner, P., & Kühne, R. (2004). Calibration and Validation of Microscopic Traffic Flow Models. *Transportation Research Record*, 1876(1), 62–70.
- Byrd, R. H., Lu, P., Nocedal, J., & Zhu, C. (1995). A Limited Memory Algorithm for Bound Constrained Optimization. *SIAM Journal on Scientific Computing*, 16(5), 1190–1208. doi:10.1137/0916069
- Chandler, R. E., Herman, R., & Montroll, E.W. (1958). Traffic Dynamics: Studies in Car Following, *Operations Research*, 6, 165-185.
- Chen, Z. (1992). *Menschliche und automatische Regelung der Längsbewegung von Personenkraftwagen* (Dissertation). VDI-Fortschrittberichte, Reihe 12, Nr. 168.
- Cohen, J. (1988). *Statistical Power analysis for the behavioral sciences*. (2nd ed.). Hillsdale, NJ: Erlbaum.
- Cohen, J. (1992). A power primer. *Psychological Bulletin*, 112(1), 155–159.
- Dowle, M., Short, T., Lianoglou, S., Srinivasan, Saporta, R., & Antonyan, E. (2014). data.table: Extension of data.frame. R package version 1.9.4.
- Faul, F., Erdfelder, E., Lang, A.-G., & Buchner, A. (2007). G*Power 3: A flexible statistical

- power analysis program for social, behavioral, and biomedical sciences. *Behavior Research Methods*, 39, 175-191.
- Fritzsche, H.T. (1994). A model for traffic simulation. *Traffic Engineering and Control*, 35(5), 317–321.
- Gazis, D. C., Herman, R., & Potts, R. B. (1959). Car following theory of steady state traffic flow. *Operations Research*, 7, 499-505.
- Gazis, D. C., Herman, R., & Rothery, R. W. (1961). Nonlinear follow the leader models of traffic flow. *Operations Research*, 9, 545-567.
- Gipps, P. G. (1981). A behavioural car-following model for computer simulation. *Transportation Research Part B: Methodological*, 15(2), 105–111. doi: 10.1016/0191-2615(81)90037-0
- Gipps, P. G. (1986). A model for the structure of lane changing-decisions. *Transportation Research Part B: Methodological*, 20(5), 403–414.
- Hamdar, S. (2012). *Driver behavior modeling*. In: A. Eskandarian (Ed.), *Handbook of Intelligent Vehicles*. Springer (pp. 537–558).
- Hashimoto, M., Suetomi, T., Okuno, A., & Uemura, H. (2001). A study on driver model for lane change judgement. *JSAE Review*, 22(2), 183-188.
- Helly, W. (1959). Simulation of bottlenecks in single-lane traffic flow. *Proceedings of the Symposium on Theory of Traffic Flow*, Research Laboratories, General Motors, New York.
- Hidas, P. (2005). Modelling vehicle interactions in microscopic simulation of merging and weaving. *Transportation Research Part C: Emerging Technology*, 13(1), 37–62. doi: 10.1016/j.trc.2004.12.003
- Hoffmann, E.R., & Mortimer, R.G. (1994). Drivers' estimates of time to collision. *Accident Analysis and Prevention*, 26, 511-520.
- Hoffmann, E. R. (1966). Note on detection of vehicle velocity changes. *Human Factors*, 8, 139-141.
- Hoogendoorn, R., Hoogendoorn, S. P., Brookhuis, K., & Daamen, W. (2010): Psychological elements in car-following models: Mental workload in case of incidents in the other driving lane. *Procedia Engineering*, 3, 87–99. doi: 10.1016/j.proeng.2010.07.010
- Hoogendoorn, S. P., & Hoogendoorn, R. (2010). Generic Calibration Framework for Joint

- Estimation of Car-Following Models by Using Microscopic Data. *Transportation Research Record: Journal of the Transportation Research Board*, 368(1928), 37–45. doi: 10.3141/2188-05
- Hoogendoorn, S. P., Ossen, S., & Schreuder, M. (2006). Empirics of multianticipative car-following behavior. *Transportation Research Record*, 1965, 112-120.
- Jürgensohn, T. (1997): *Hybride Fahrermodelle* (Dissertation). Sinzheim: Pro Universitate Verlag.
- Krauß, S. (1998): Microscopic Modeling of Traffic Flow; Investigation of Collision Free Vehicle Dynamics (Dissertation). Universität zu Köln, Köln.
- Lee, D. N. (1976). A theory of visual control of braking based on information about time to collision. *Perception*, 5, 437-459.
- Lewandowsky, S., & Farrell S. (2011). *Computational modeling in cognition: principles and Practice*. Thousand Oaks, CA: Sage
- MacCallum, R. C. (2003). Working with imperfect models. *Multivariate Behavioral Research*, 38(1), 113-139.
- Michaels, R. M. (1963). Perceptual factors in car following. *Proceedings of the Second International Symposium on the Theory of Road Traffic Flow* (pp. 44-59). Paris: OECD.
- Michon, J. A. (1985). A critical view of driver behavior models: What do we know, what should we do. In: L. Evans & R. C. Schwing (Eds.), *Human Behavior and Traffic Safety*. New York: Plenum.
- Mortimer, R. G. (1971). The value of an accelerator release signal. *Human Factors*, 13, 481-486.
- Olstam, J.J., & Tapani, A. (2004). *Comparison of Car-following Models*. Swedish National Road and Transport Research Institute.
- Ossen, S. (2008). *Logitudinal Driving Behavior: Theory and Empirics* (Doctoral Dissertation). TRAIL Thesis Series, T2008/8 (September 2008).
- Ossen, S., & Hoogendoorn, S. P. (2011). Heterogeneity in car-following behavior: Theory and empirics. *Transportation Research Part C: Emerging Technologies*, 19(2), 182–195. doi: 10.1016/j.trc.2010.05.006
- Panwai, S., & Dia, H. (2005). Comparative evaluation of microscopic car-following behavior. *IEEE Transaction on Intelligent Transportation Systems*, 6(3), 314–325.

- Pipes, L. A. (1953). An Operational Analysis of Traffic Dynamics, *Journal of Applied Physics*, 24(3), 274-281.
- Prokop, G. (2001). Modeling human vehicle driving by model predictive online optimisation. *Vehicle System Dynamics*, 35(1), 19–53.
- Ranjitkar, P., Kawamua, A., & Nakatsuji, T. (2005). Car-following models: An experiment based benchmarking, *Journal of the Eastern Asia Society for Transportation Studies*, 6, 1582–1596.
- Rinderknecht, S. L., & Reichert, P. (2013). fitDRC: Fitting Density Ratio Classes. R package version 1.1.
- Ripley, B., & Lapsley, M. (2014). RODBC: ODBC Database Access. R package version 1.3-10.
- Rockwell, T. H., Ernst, R. L., & Hanken, A. (1968). A sensitivity analysis of empirically derived car following models. *Transportation Research*, 2, 363-373.
- Schmider, E., Ziegler, M., Danay, E., Beyer, L., & Bühner, M. (2010). Is It Really Robust? *Methodology: European Journal of Research Methods for the Behavioral and Social Sciences* 6(4), 147–151. doi: 10.1027/1614-2241/a000016
- Schunn, C.D., & Wallach, D. (2005). Evaluating goodness-of-fit in comparison of models to data. In: W. Track (ed.), *Psychologie der Kognition: Reden und Vorträge anlässlich der Emeritierung von Werner Tack* (pp. 115–154). Saarbrücken: University of Saarland Press.
- Shinar, D. (2007). *Traffic safety and human behavior*. Oxford, UK: Elsevier.
- Sun, R. (2008). Introduction to Computational Cognitive Modeling. In: Ron Sun (ed.), *The Cambridge Handbook of Computational Psychology* (pp. 3-20). Cambridge: Cambridge University Press. doi: <http://dx.doi.org/10.1017/CBO9780511816772.003>
- Soria, I., Elefteriadou, L., & Kondyli, A. (2014). Assessment of car-following models by driver type and under different traffic, weather conditions using data from an instrumented vehicle. *Simulation Modelling Practice and Theory*, 40, 208–220. doi: 10.1016/j.simpat.2013.10.002
- Stadt Braunschweig – Open GeoData, 2014, Lizenz: dl-de/by-2-0 (die markierte Strecke und die Bezeichnungen wurden nachträglich hinzugefügt).
- Timpe, K. P. (1966). Die Beschreibung einfacher Trackingleistungen mit Hilfe eines

- zeitoptimalen Prozesses, *Elektronische Informationsverarbeitung und Kybernetik*, 2(2), 107-119.
- Treiber, M., & Kesting, A. (2013). *Traffic Flow Dynamics: Data, Models and Simulation*. Springer-Verlag, Berlin Heidelberg, ISBN 978-3-642-32459-8.
- Van Winsum, W. (1999). The human element in car following models. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2(4), 207-211. doi: 10.1016/S1369-8478(00)00008-5
- Waigand, D. (2011). Entwicklung und Optimierung eines Verfahrens zur Erhebung von Fahrdaten in Feldversuchen (unpublished bachelor thesis). Deutsches Zentrum für Luft- und Raumfahrt e.V., Braunschweig.
- Wickham, H. (2007). Reshaping Data with the reshape Package. *Journal of Statistical Software*, 21(12), 1-20.
- Wickham, H. (2011). The Split-Apply-Combine Strategy for Data Analysis. *Journal of Statistical Software*, 40(1), 1-29.
- Wickham, H. (2012). stringr: Make it easier to work with strings. R package version 0.6.2.
- Wiedemann, R. (1974). Simulation des Straßenverkehrsflusses. *Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe*, 8.
- Wiedemann, R., & Reiter, U. (1992). *Microscopic traffic simulation: the simulation system MISSION, background and actual state, CEC Project ICARUS (VI052)*, Final Report, vol. 2, Appendix A. Brussels: CEC.
- Zeileis, A., & Grothendieck, G.(2005). zoo: S3 Infrastructure for Regular and Irregular Time Series. *Journal of Statistical Software*, 14(6), 1-27.

Anhang

Liste der Anhänge

Anhang A: Kalibrierte Werte für die freien Modellparameter

Anhang B: Modellgütekennwerte

Anhang C: Übersicht & Erläuterungen der angefügten Dateien

Anhang D: Variablenliste in R (Datensatz „data.parEst“)

Anhang E: Variablenliste in SPSS (Datensatz „Modellgüte“)

Anhang F: Eigenständigkeitserklärung

Anhang G: Genehmigung zur Veröffentlichung

Anhang

Anhang A

Mittelwerte (M) und Standardabweichungen (SD) der kalibrierten Werte für die freien Parameter aller Modelle pro Variable (Distanz und Geschwindigkeit)

Helly	T _R				k				j				f				d _{min}			
	Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit	
	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD
Autobahn	0,94	0,35	0,60	0,39	0,29	0,25	3,20	2,47	0,15	0,11	0,34	0,22	0,98	0,19	1,27	0,45	6,90	3,10	5,46	1,65
Landstraße	0,95	0,38	0,65	0,53	0,35	0,14	4,26	2,95	0,07	0,06	0,43	0,55	1,25	0,30	1,36	0,59	5,99	0,09	5,03	2,06
Stadt	0,79	0,27	0,37	0,33	0,48	0,17	4,69	3,26	0,28	0,26	0,18	0,31	1,01	0,27	1,43	2,57	5,79	0,53	5,49	1,66
DVA	T _R				k				j				d _{time}							
	Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit					
	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD				
Autobahn	0,97	0,14	0,94	0,27	0,24	0,42	0,11	0,20	-799,21	-799,17	2,23	2,29	2,29	0,50	2,47	1,28				
Landstraße	1,01	0,02	0,74	0,34	0,12	0,27	0,06	0,11	-799,97	-807,10	0,53	23,57	2,17	0,38	2,14	0,80				
Stadt	0,96	0,12	0,85	0,31	0,53	1,09	1,65	5,27	-799,80	-800,48	0,76	4,20	2,38	0,58	2,20	0,40				
DVA-PT	T _R				k				j				d _{time}							
	Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit					
	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD				
Autobahn	0,98	0,05	0,90	0,22	0,58	1,00	0,24	0,33	-800,26	0,66	-800,02	0,55	2,16	0,22	2,32	0,40				
Landstraße	1,01	0,04	0,66	0,40	0,14	0,30	2,28	4,56	-800,28	0,68	-822,17	47,93	2,43	0,51	1,95	1,11				
Stadt	0,83	0,31	0,58	0,41	1,20	1,76	0,05	0,07	-800,51	2,03	-802,10	6,24	2,36	0,67	7,44	9,45				
Gipps	T _R				b _{max}				b _{est}				d _{min}							
	Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit		Distanz		Geschwindigkeit					
	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD	M	SD				
Autobahn	1,02	0,19	0,58	0,35	-3,60	1,07	-2,70	0,38	-3,24	0,84	-3,06	0,28	2,95	0,16	2,75	0,56				
Landstraße	1,00	0,05	0,56	0,38	-3,04	0,09	-2,64	1,00	-2,97	0,10	-2,78	1,07	2,99	0,03	4,39	3,33				
Stadt	0,97	0,05	0,47	0,37	-3,14	0,19	-2,47	1,22	-2,87	0,19	-2,19	1,08	2,98	0,05	3,40	0,80				

Anhang

Anhang B

Mittelwerte (M) und Standardabweichungen (SD) der Vorhersagegüte aller Modelle pro Variable (Distanz und Geschwindigkeit) und Gütemaß (RMSD und r)

Distanz/RMSD									Distanz/r								
Helly		DVA		DVA-PT		Gipps			Helly		DVA		DVA-PT		Gipps		
M	SD	M	SD	M	SD	M	SD		M	SD	M	SD	M	SD	M	SD	
Autobahn	6,53	2,15	7,96	2,41	8,97	3,82	7,26	2,34	Autobahn	0,55	0,16	0,42	0,20	0,40	0,20	0,36	0,24
Landstraße	7,45	1,99	12,89	3,70	10,72	3,22	8,48	2,81	Landstraße	0,53	0,10	0,29	0,18	0,41	0,18	0,37	0,16
Stadt	3,95	0,85	11,90	4,20	10,36	4,78	4,16	0,97	Stadt	0,74	0,10	0,29	0,21	0,40	0,23	0,71	0,10
Geschw./RMSD									Geschw./r								
Helly		DVA		DVA-PT		Gipps			Helly		DVA		DVA-PT		Gipps		
M	SD	M	SD	M	SD	M	SD		M	SD	M	SD	M	SD	M	SD	
Autobahn	0,65	0,11	1,03	0,33	1,07	0,33	0,65	0,13	Autobahn	0,97	0,02	0,91	0,07	0,93	0,04	0,97	0,02
Landstraße	0,84	0,21	1,54	0,54	1,35	0,64	0,83	0,17	Landstraße	0,97	0,01	0,89	0,08	0,93	0,05	0,97	0,01
Stadt	0,98	0,16	2,18	0,65	1,73	0,81	1,07	0,26	Stadt	0,97	0,01	0,83	0,10	0,89	0,10	0,96	0,02

Anhang C

Übersicht und Erläuterung der beigelegten Dateien

R-Skripte

Mithilfe der Software R wurde die Aufbereitung der empirisch erhobenen Daten vorgenommen, die Kalibrierung der Modelle und die Bestimmung der Modellgüte.

„1 Daten einlesen.r“

[Liest die Daten vom Server in R ein]

„2 Daten aufbereiten.r“

[Führt alle Funktionen für die Datenaufbereitung aus]

„2.1 Daten bereinigen.r“

[Funktion zur Bereinigung von Artefakten]

„2.2 Zeiteinheit vergrößern.r“

[Funktion, um Datensatz von 25Hz(40ms)-Einheiten auf 5Hz(200ms)-Einheiten zu transformieren]

„2.3 neue Variablen.r“

[Funktionen zur Berechnung von Streckentypen, Schwinke, Beschleunigung, Geschwindigkeit des VF]

➔ Ergebnisdokument: „data.parEst.csv“

[aufbereitete Daten – fertig für die Parameterschätzung]

„3 Modelle kalibrieren.r“

[Führt alle Funktionen für die Modellkalibrierung aus]

„3.1 Auswahl Daten.r“

[Matrix mit den Namen der zu kalibrierenden Ausschnitte]

„3.2 Gütemass.r“

[Funktion zur Berechnung der Modellgüte für verschiedene Maße]

„3.3 Par schätzen.r“

[Funktion zur Kalibrierung der Modellparameter – enthält den Optimierungsalgorithmus]

„3.3.1 – 3.3.4 predModell.r“

[Funktion zur Produktion der Modellvorhersagen]

➔ Ergebnisdokumente: „fit&par_Modell_Variable_RMSD.csv“

[pro Modell und Variable mit Parameterwerten und Modellgüte für RMSD]

„4 Modellguete für r.r“

[Berechnet die Güte der Modelle mit r]

➔ Ergebnisdokumente: „fit_Modell_Variable_r.csv“

[pro Modell und pro Variable mit der Modellgüte für r]

„5 deskr. Auswertung empirischer Daten.r“

[Berechnet Mittelwerte und Standardabweichungen der empirischen Daten]

„6 Exemplarische Plots.r“

[Fertigt die in der Arbeit aufgeführten Plots an]

Excel-Dateien

Das Office-Programm Excel wurde genutzt, um die Ergebnis-Dateien für die Modellgüte und den Parameterwerten übersichtlich aufzubereiten und die Daten der einzelnen Individuen zu aggregieren.

„Modellgüte.xls“

„Parameter.xls“

SPSS-Dateien

Mit der Software SPSS wurden statistische Analysen der Modellgütekennwerte vorgenommen, die zur Beantwortung der Forschungsfragestellungen dienen.

„Modellgüte.sav“ *[Datenblatt]*

„Modellgüte_umstruk.sav“ *[Datenblatt, umstrukturiert zur Berechnung der ANOVA]*

„Analysen.sps“ *[Syntax]*

„explorative Datenanalyse.spv“ *[Output]*

„Testergebnisse.spv“ *[Output]*

Anhang D

Variablenliste in R (Datensatz „data.parEst“)

Variablenname	Beschreibung
stid	„State ID“ = Nummerierung der einzelnen Loggingevents
Time	Unixzeit
Subj	Probandennummer
route	Streckentyp Autobahn = hway1, hway2 Landstraße = ctry1, ctry2 Stadt = cityRing1, cityRing2, cityRing3, cityRing4
Dist	Distanz zwischen Vorderfahrzeug und Folgefahzeug (in Meter)
alpha	Sehwinkel in rad/s
vEgo	Geschwindigkeit des Folgefahrzeugs
aEgo	Beschleunigung des Folgefahrzeugs
vLead	Geschwindigkeit des Vorderfahrzeugs
aLead	Beschleunigung des Vorderfahrzeugs

Anhang E

Variablenliste in SPSS (Datensatz „Modellgüte“)

Variablenname	Beschreibung
Subject	Probandennummer
model	Folgefahrtmodelle Helly = 1 DVA = 2 DVAPT = 3 Gipps = 4
route	Streckentyp Autobahn = 1 Landstraße = 2 Stadt = 3
dist_RMSD	Abweichung mittels RMSD (Wurzel des Mittelwerts der quadrierten Differenz) zwischen Distanzvorhersage und empirischer Distanz (in Meter)
dist_R	Zusammenhang zwischen Distanzvorhersage und empirischer Distanz (Pearson-Korrelationskoeffizient) Rohwerte wurden mit -1 multipliziert
speed_RMSD	Abweichung mittels RMSD (Wurzel des Mittelwerts der quadrierten Differenz) zwischen Geschwindigkeitsvorhersage und empirischer Geschwindigkeit (in Meter)
speed_R	Zusammenhang zwischen Geschwindigkeitsvorhersage und empirischer Geschwindigkeit (Pearson-Korrelationskoeffizient) Rohwerte wurden mit -1 multipliziert

Anhang F

Eigenständigkeitserklärung:

Hiermit erkläre ich, dass ich die vorliegende Masterarbeit mit dem Titel “Der Faktor Mensch in quantitativen Fahrermodellen des Folgefahrens: Ein Modellvergleich” selbstständig und ohne fremde Hilfe verfasst habe. Ich versichere, dass ich keine anderen als die angegebenen Quellen benutzt und alle wörtlich oder sinngemäß aus anderen Werken übernommenen Aussagen als solche gekennzeichnet habe, und dass die eingereichte Arbeit weder vollständig noch in wesentlichen Teilen Gegenstand eines anderen Prüfungsverfahrens gewesen ist.

Ort, Datum

Unterschrift Diana Kuhl

Anhang G

Genehmigung zur Veröffentlichung:

Ich bin damit einverstanden, dass die vorliegende Masterarbeit mit dem Titel „Der Faktor Mensch in quantitativen Fahrermodellen des Folgefahrens: Ein Modellvergleich“ in Bibliotheken öffentlich zugänglich gemacht wird.

Ort, Datum

Unterschrift Diana Kuhl